


Ricardo Hugo Lira-Saldivar y Francisco Marcelo Lara-Viveros

Inteligencia Artificial en Agricultura

Uso de Algoritmos, Drones y Biosensores



Ricardo Hugo Lira-Saldivar y Francisco Marcelo Lara-Viveros

Inteligencia Artificial en Agricultura

Uso de Algoritmos, Drones y Biosensores



Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Camila Alves de Cremo

Ellen Andressa Kubisty

Luiza Alves Batista

Nataly Evilin Gayde

Thamires Camili Gayde

Imagens da capa

iStock

Edição de arte

Luiza Alves Batista

2023 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2023 Os autores

Copyright da edição © 2023 Atena

Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo do texto e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial

Ciências Agrárias e Multidisciplinar

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano

Profª Drª Amanda Vasconcelos Guimarães – Universidade Federal de Lavras

Prof. Dr. Arinaldo Pereira da Silva – Universidade Federal do Sul e Sudeste do Pará

Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás

Profª Drª Carla Cristina Bauermann Brasil – Universidade Federal de Santa Maria

Prof. Dr. Cleberton Correia Santos – Universidade Federal da Grande Dourados
 Profª Drª Diocléa Almeida Seabra Silva – Universidade Federal Rural da Amazônia
 Prof. Dr. Écio Souza Diniz – Universidade Federal de Viçosa
 Prof. Dr. Edevaldo de Castro Monteiro – Universidade Federal Rural do Rio de Janeiro
 Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
 Prof. Dr. Fágner Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará
 Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
 Prof. Dr. Guilherme Renato Gomes – Universidade Norte do Paraná
 Prof. Dr. Jael Soares Batista – Universidade Federal Rural do Semi-Árido
 Prof. Dr. Jayme Augusto Peres – Universidade Estadual do Centro-Oeste
 Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro
 Profª Drª Lina Raquel Santos Araújo – Universidade Estadual do Ceará
 Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa
 Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
 Prof. Dr. Renato Jaqueto Goes – Universidade Federal de Goiás
 Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
 Profª Drª Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro
 Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido
 Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

Inteligencia artificial en agricultura - Uso de algoritmos, drones y biosensores

Diagramação: Letícia Alves Vitral
Correção: Flávia Roberta Barão
Indexação: Amanda Kelly da Costa Veiga
Revisão: Os autores
Autores: Ricardo Hugo Lira-Saldivar
Francisco Marcelo Lara-Viveros

Dados Internacionais de Catalogação na Publicação (CIP)	
L768	<p>Lira-Saldivar, Ricardo Hugo Inteligencia artificial en agricultura - Uso de algoritmos, drones y biosensores / Ricardo Hugo Lira-Saldivar, Francisco Marcelo Lara-Viveros. – Ponta Grossa - PR: Atena, 2023.</p> <p>Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-65-258-1705-7 DOI: https://doi.org/10.22533/at.ed.057230409</p> <p>1. Automatización agrícola - agricultura utilizando tecnología de inteligencia artificial. I. Lira-Saldivar, Ricardo Hugo. II. Lara-Viveros, Francisco Marcelo. III. Título. CDD 631.584</p>
Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166	

Atena Editora
Ponta Grossa – Paraná – Brasil
Telefone: +55 (42) 3323-5493
www.atenaeditora.com.br
contato@atenaeditora.com.br

DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao conteúdo publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que o texto publicado está completamente isento de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.

DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.

Los rendimientos agrícolas dependen totalmente de las condiciones climáticas, debido a eso las tecnologías dependientes de la inteligencia artificial (IA) ayudan a mejorar la producción y la eficacia del sector agrícola mediante el monitoreo de los cultivos, el crecimiento y desarrollo de las plantas, la detección del contenido de humedad y nutrientes del suelo, la presencia de malezas y plagas, etc.

Queda claro que la IA está desempeñando una función cada vez más importante en diversas áreas de investigación científica y aplicaciones del mundo real, que van desde el diseño de AlphaGo, hasta el análisis de imágenes agrícolas, la predicción de terremotos, la clasificación de especies de plantas en el terreno, la estimación de la madurez de la fruta y hasta la recomendación en línea de agroquímicos.

En muchas investigaciones sobre inteligencia artificial se tiene como objetivo revisar la utilidad de diversas técnicas de IA en la agricultura como: la lógica difusa, red neuronal artificial, algoritmo genético, optimización de enjambre de partículas, recocido simulado, optimización de colonias de hormigas, algoritmo de colonias de abejas artificiales, algoritmo de búsqueda de armonía, algoritmo de murciélagos, descomposición celular y el algoritmo de luciérnagas.

La agricultura es crucial para la vida humana porque es el principal proveedor de alimentos, pero sigue siendo muy dependiente del cambio climático y otros desafíos, especialmente en los países en desarrollo. Algunos de los mayores desafíos de la humanidad están relacionados con la vigilancia y el monitoreo del clima, los recursos hídricos y la calidad del suelo. La evolución de la IA para mejorar la agricultura, así como los sistemas integrados y el Internet de las cosas (IoT) es innegable. Debido a eso, su adopción a gran escala en las actividades agrícolas ofrece una gran oportunidad para superar muchos de estos desafíos.

INTELIGENCIA ARTIFICIAL EN LA AGRICULTURA MODERNA.....	1
INTRODUCCIÓN	1
AGROSISTEMAS DE INTELIGENCIA ARTIFICIAL.....	2
SISTEMAS DE INTELIGENCIA ARTIFICIAL PARA LA AGRICULTURA.....	3
INTELIGENCIA ARTIFICIAL PARA EL MANEJO Y CONSERVACIÓN DEL AGUA.....	6
LA INTELIGENCIA ARTIFICIAL EN FITOPLAGAS	9
INTELIGENCIA ARTIFICIAL PARA DIAGNOSTICO NUTRICIONAL DE CULTIVOS	12
INTELIGENCIA ARTIFICIAL PARA EL MANEJO Y COSECHA DE CULTIVOS	15
INTELIGENCIA ARTIFICIAL PARA EL MANEJO DE INVERNADEROS	18
CONCLUSIONES	25
LITERATURA CITADA.....	27
 INTELIGENCIA ARTIFICIAL EN LA AGRICULTURA PROTEGIDA	31
INTRODUCCIÓN	31
AGRICULTURA PROTEGIDA VERTICAL	32
USOS DE LA INTELIGENCIA ARTIFICIAL EN BIOESPACIOS Y CAMPO ABIERTO	37
USOS DE LA INTELIGENCIA ARTIFICIAL EN LA PRODUCCIÓN DE ALIMENTOS.....	41
CONCLUSIONES	43
LITERATURA CITADA.....	44
 INTELIGENCIA ARTIFICIAL CONTRA PLAGAS Y ENFERMEDADES	46
INTRODUCCIÓN	46
INTELIGENCIA ARTIFICIAL EN LA DETECCIÓN Y CLASIFICACIÓN DE PLAGAS.....	47
INTELIGENCIA ARTIFICIAL EN PREVENCIÓN Y CONTROL DE PLAGAS Y ENFERMEDADES	49
INTELIGENCIA ARTIFICIAL CONTRA LA MOSQUITA BLANCA.....	53
INTELIGENCIA ARTIFICIAL CONTRA TRIPS	58

INTELIGENCIA ARTIFICIAL CONTRA GUSANO COGOLLERO.....	62
CONCLUSIONES	65
LITERATURA CITADA.....	67
 INTELIGENCIA ARTIFICIAL EN PRODUCCIÓN DE FRUTALES	71
INTRODUCCIÓN	71
INTELIGENCIA ARTIFICIAL EN VIÑEDOS Y LA VITICULTURA.....	71
INTELIGENCIA ARTIFICIAL EN HUERTOS DE MANZANA	75
INTELIGENCIA ARTIFICIAL EN HUERTOS DE PALMAS.....	78
INTELIGENCIA ARTIFICIAL EN HUERTOS DE CÍTRICOS.....	83
INTELIGENCIA ARTIFICIAL EN HUERTOS DE BANANOS.....	86
INTELIGENCIA ARTIFICIAL EN HUERTOS DE MANGOS	89
INTELIGENCIA ARTIFICIAL EN HUERTOS DE AGUACATE.....	92
CONCLUSIONES	99
LITERATURA CITADA.....	100
SOBRE LOS AUTORES.....	105

INTELIGENCIA ARTIFICIAL EN LA AGRICULTURA MODERNA

INTRODUCCIÓN

La agricultura es un tema de preocupación en todo el mundo debido al rápido aumento sin precedentes de la población y porque tiene una influencia clave en la producción global de alimentos, la seguridad social y la economía; sin embargo, hay un gran problema: El Cambio Climático, el cual afecta a la agricultura de muchas maneras, ya que están entrelazados, y esa es la fuerza impulsora detrás de los estreses bióticos y/o abióticos que sufren los cultivos agrícolas (Riaz et al., 2023).

Los rendimientos dependen totalmente de las condiciones climáticas, debido a eso las tecnologías dependientes de la inteligencia artificial (IA) ayudan a mejorar la producción y la eficacia del sector agrícola, es decir, el monitoreo de los cultivos, el establecimiento de las plantas, la detección del contenido de humedad y nutrientes del suelo, presencia de malezas y plagas, etc. (Saxena et al., 2023).

El consumo excesivo de herbicidas ha llevado gradualmente al fenómeno de la resistencia de las malezas a los herbicidas, por lo que el manejo adecuado de malezas resistentes solo puede lograrse mediante la aplicación de estrategias de alta tecnología, como métodos basados en la IA (Ghatrehsamani et al., 2023).

Queda claro que la IA está desempeñando una función cada vez más importante en diversas áreas de investigación científica y aplicaciones del mundo real, que van desde el diseño de AlphaGo hasta el análisis de imágenes agrícolas, la predicción de terremotos, la clasificación de especies de peces y la estimación de la madurez de la fruta, hasta la recomendación en línea de productos (Xue et al., 2023).

Acorde con Wakchaure et al. (2023), en muchas investigaciones sobre IA se tiene como objetivo revisar la utilidad de diversas técnicas de IA como: la lógica difusa, red neuronal artificial, algoritmo genético, optimización de enjambre de partículas, recocido simulado, optimización de colonias de hormigas, algoritmo de colonias de abejas artificiales, algoritmo de búsqueda de armonía, algoritmo de murciélagos, descomposición celular y algoritmo de luciérnagas en la agricultura.

La agricultura es crucial para la vida humana porque es el principal proveedor de alimentos, pero sigue siendo muy dependiente del cambio climático y otros desafíos, especialmente en los países en desarrollo. El estudio de Mana et al. (2023) consigna que algunos de los mayores desafíos de la humanidad están relacionados con la vigilancia y el monitoreo del clima, los recursos hídricos y la calidad del suelo. La evolución de la IA para mejorar la agricultura, así como los sistemas integrados y el Internet de las cosas (IoT) es

innegable. Debido a eso, su adopción a gran escala en las actividades agrícolas ofrece una gran oportunidad para superar muchos de estos desafíos.

AGROSISTEMAS DE INTELIGENCIA ARTIFICIAL

La IA puede ayudar a enfrentar desafíos ocasionados por factores bióticos y abióticos, mejorar la toma de decisiones y aumentar la eficiencia en la producción de alimentos. La agricultura es una industria que se verá muy beneficiada por las aportaciones de la IA en todos los aspectos de la vida de las plantas (Figura 1).

En los últimos años, el uso de modelos de IA y aprendizaje automático (ML) dentro del mundo de la agricultura ha aumentado significativamente (Talaviya et al., 2020), hasta el punto de que se espera que el gasto en tecnologías de IA dentro del sector aumente en un 25 % durante los próximos 4 años.

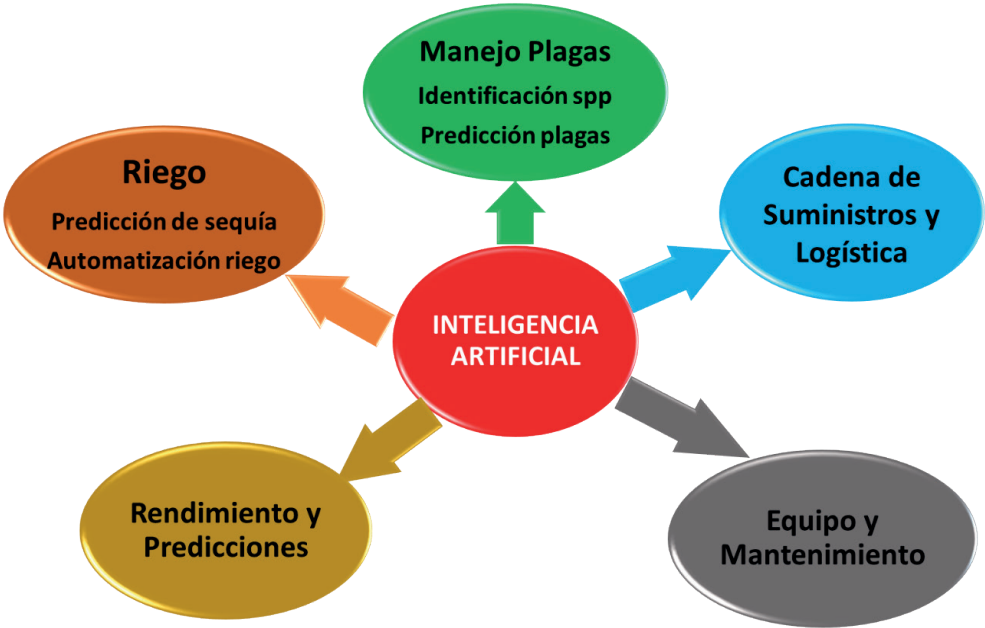


Figura 1. La inteligencia artificial tiene grandes posibilidades de aplicación en la agricultura, especialmente en diversos temas como aplicación del riego y nutrientes, control de plagas y enfermedades, predicción del crecimiento, rendimiento y la calidad de la cosecha (Adaptado de Talaviya et al., 2020).

La IA se está aplicado mucho en la agricultura sustentable, ya que se ha venido usando para desarrollar cultivos más sanos, para aplicar menores volúmenes de agroquímicos, realizar un manejo adecuado de plagas y enfermedades, monitorear el suelo y las condiciones de cultivo, analizar datos para los agricultores y mejorar otras actividades de la cadena de suministro de alimentos (Figura 2).

Javid et al. (2023) mencionan que la IA también ofrece datos sobre las previsiones

meteorológicas que ayudarán a los agricultores a producir más con menos recursos, aumentar la calidad de los cultivos y acelerar el tiempo de llegada del producto al mercado. Las imágenes hiperespectrales y el escaneo láser 3D son las principales tecnologías basadas en IA que pueden ayudar a garantizar la salud de los cultivos.

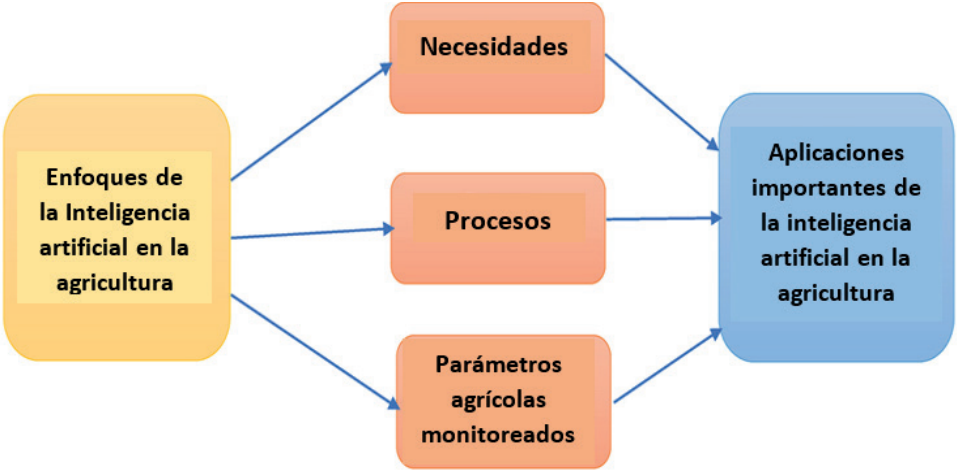


Figura 2. La inteligencia artificial apoyada en drones para capturar imágenes hiperespectrales e imágenes en 3D permite obtener una gran cantidad de imágenes de la sanidad del cultivo, condiciones del suelo y estado hídrico de las plantas entre otras variables (Adaptado de: Javid et al., 2023).

El reporte de Sireni et al. (2022) indica que, de la superficie total de cultivo en la India, solo el 39% es de riego y 61% es de temporal o seco. Si la lluvia falla en un período de tiempo en particular hay daño en los cultivos. Entonces, ese es el momento en que se requieren prácticas agrícolas eficientes con la ayuda de la IA.

Al introducir la IA, las antiguas prácticas agrícolas tradicionales cambiarán por completo, lo que se ya se está presenciando hoy. Por lo tanto, la IA brinda muchas soluciones, y ya representa una estrategia factible para que los cultivos mejoren los rendimientos y reduzcan el costo del paquete tecnológico de los cultivos.

SISTEMAS DE INTELIGENCIA ARTIFICIAL PARA LA AGRICULTURA

La seguridad alimentaria es una de las prioridades de todos los países del mundo. Sin embargo, diferentes factores están dificultando el cumplimiento de los objetivos globales de seguridad alimentaria. Se han realizado diversas acciones con sistemas de IA orientadas a la seguridad alimentaria, y ha quedado claro que la IA es un método moderno que está apoyando en varias etapas el sistema alimentario.

Kutyauripo et al. (2023) indican que la IA mejora la productividad agrícola; optimiza las operaciones de cosecha y poscosecha, de manera que los productores agrícolas pueden aplicar la IA en decisiones orientadas a la producción de alimentos. Además, los

residuos agroalimentarios se pueden manejar adecuadamente usando IA, por lo que ya se emplean varios algoritmos de IA en los sistemas alimentarios.

Las enfermedades de las hojas de tomate tienen un gran impacto en el rendimiento y la calidad. Sudar et al. (2022) reportan que los sistemas de IA para el análisis en etapa temprana y la categorización de las enfermedades del cultivo de tomate en base a conocimientos previos, pueden ayudar a limitar la transmisión de patógenos en todo el campo agrícola y al mismo tiempo, ayudan a aumentar el rendimiento de los cultivos. Usando una red neuronal convolucional profunda, también se puede determinar el estado de madurez de los tomates en las plantas (Figura 3).



Figura 3. Los sistemas de inteligencia artificial pueden detectar en tiempo real el grado de madurez de los frutos, además permiten averiguar la presencia de plagas y enfermedades en el follaje (Tomado de: <https://intellias.com/artificial-intelligence-in-agriculture/>).

El desarrollo progresivo de sistemas de información intelectuales y expertos en la agricultura requiere un conocimiento más fundamental sobre las características únicas de los ecosistemas y la agricultura local, especialmente para las regiones con condiciones climáticas extremas como el norte de Asia.

Kalichkin et al. (2023) señalan que cada parcela agrícola necesita una gran cantidad de personalización específica para las aplicaciones de la tecnología digital, lo que plantea la necesidad de una organización eficaz de la base de conocimientos, para así poder realizar un análisis de datos y generar mediante IA diversos modelos de simulación eficiente en tiempo real (Figura 4).



Figura 4. El desarrollo actual de la inteligencia artificial permite que los agrónomos y productores puedan caracterizar en tiempo real diversas variables del ambiente aéreo, la humedad del suelo, la nutrición de las plantas, el estado fenológico de las plantas, así como sobre la presencia de plagas y enfermedades (Tomado de: <https://venturebeat.com/ai/ai-delivers-real-time-data-for-smarter-farming/>).

El calentamiento global y la creciente demanda de alimentos son problemas de la generación actual por lo que se requiere un cambio hacia una agricultura de altos rendimientos que sea sustentable y de bajo impacto. Witte et al. (2023) advierten que en la última década la investigación en el campo de la IA ha avanzado considerablemente.

Por lo tanto, el uso de sistemas de IA en la agricultura puede ser una solución prometedora para garantizar un suministro suficiente de alimentos a escala mundial. En ese sentido, los sistemas de cámaras instalados en drones proporcionan imágenes que son procesados en la computadora como datos, para usarse en sistemas basados en IA en la agricultura ecológica y sustentable.

Información sobre distribución espacial y las posibles fuentes de contaminación por metales pesados en tierras agrícolas es muy importante para la salud humana y la seguridad alimentaria. Debido a eso, Günal et al. (2023) evaluaron el grado de contaminación por plomo (Pb), cadmio (Cd) y níquel (Ni) en la parte sureste de Turquía, mediante el índice de geoacumulación (Igeo), el factor de contaminación modificado (mCdeg) y el índice de contaminación de Nemerow (PINemerow), los cuales fueron combinados con autocorrelación espacial utilizando algoritmos de aprendizaje profundo.

Los resultados indican que los índices de contaminación generados tuvieron más éxito que las simples concentraciones de metales pesados en la interpretación de los niveles de riesgo de contaminación. Por lo tanto, la información espacial de alta resolución

obtenida con IA puede ayudar a los legisladores y autoridades a reducir las emisiones de metales pesados, si es posible, hasta eliminar la contaminación.

Para satisfacer la demanda mundial de alimentos, los agricultores utilizan grandes cantidades de pesticidas para mejorar la calidad y cantidad de las cosechas. Sin embargo, consumir alimentos de cultivos contaminados por pesticidas reduce la calidad y expectativa de vida humana.

Para superar el problema antes mencionado y mejorar la esperanza de vida, Jadav et al. (2023) propusieron un sistema de agricultura inteligente potenciado por IA para predecir la cantidad de pesticidas en los cultivos más allá del umbral permitido. El sistema planteado se evaluó con métricas de rendimiento, como precisión, escalabilidad de blockchain y latencia. Los resultados muestran que el sistema potenciado por IA superó en precisión, escalabilidad y latencia cuando fue comparado con los sistemas de referencia.

INTELIGENCIA ARTIFICIAL PARA EL MANEJO Y CONSERVACIÓN DEL AGUA

Casi el 70% del agua dulce del mundo se utiliza para el riego agrícola; por eso al implementar su automatización mediante el uso de drones, se puede conservar el agua y beneficiar a los agricultores durante el manejo de este recurso hídrico. El riego es uno de los procesos más intensivos en mano de obra en la agricultura.

En el trabajo de Dharmaraj y Vijayanand (2018) señala que máquinas entrenadas por IA, contando con el patrón climático histórico, la calidad suelo y tipo de cultivos a sembrar, pueden automatizar el riego y aumentar el rendimiento del agua. En este contexto la significancia del uso de drones según el Price Water House Coopers, el mercado total disponible de soluciones basadas en drones en todo el mundo es de \$127.3 mil millones; mientras que para el mercado agrícola es de \$32.4 mil millones.

Las soluciones orientadas al sector agrícola son para enfrentar situaciones adversas de condiciones climáticas, mejorar la agricultura de precisión, las ganancias y el manejo agronómico de los cultivos. La influencia de la IA en la gestión del agua (Figura 5) es uno de los temas cruciales discutidos en la mayoría de los foros internacionales. La recolección y el reciclaje de agua son los principales requisitos para satisfacer la próxima demanda mundial de la crisis hídrica. Para lograr esto, necesitamos más énfasis en las técnicas de manejo del agua de riego.

Esas son tendencias recientes en el reciclaje de aguas residuales, la distribución de agua, la recolección de agua de lluvia y el manejo del riego utilizando varios modelos de IA y algoritmos. Krishnan et al. (2022) sugieren que los datos adquiridos para estas

aplicaciones son únicos y también difieren según el tipo de información.

Por lo tanto, existe una gran necesidad de utilizar un modelo o algoritmo que se pueda aplicar para proporcionar soluciones en todas estas aplicaciones. Las técnicas de IA y aprendizaje profundo (DL) junto con el marco de Internet de las cosas (IoT) pueden facilitar el diseño de un sistema inteligente de manejo del agua para el uso sostenible de este recurso natural.



Figura 5. El manejo del agua apoyado por la inteligencia artificial involucra el uso de varias técnicas y aplica parámetros ambientales para brindar soluciones para la cosecha de agua de lluvia, el reciclaje de aguas residuales y la conservación del recurso hídrico para la agricultura (Adaptado de: Krishnan et al. 2022).

La IA y el aprendizaje automático tienen que ver con el uso de datos para hacer inferencias eficientes para predecir el futuro y tomar las decisiones adecuadas. Estas decisiones se toman como humanas, pero por máquinas. El aprendizaje automático y los grandes datos están teniendo un mayor impacto en la forma en que vive la sociedad actual.

El reporte de Menaga y Vasantha (2022) consigna que los modelos populares de aprendizaje automático más usados en la agricultura son: (a) Manejo agronómico de cultivos, haciendo determinación de rendimiento, detección de malezas y enfermedades; (b) Manejo del suelo y (c) Manejo del agua.

La agricultura tiene una función importante en el crecimiento económico y el

desarrollo. A lo largo de los años las mejoras tecnológicas basadas en la IA han tenido un impacto profundo en la agricultura y han transformado el negocio. Por lo tanto, esas tecnologías podrían ayudar a los agricultores a ser proactivos en lugar de reactivos en sus prácticas agrícolas tradicionales (Kaur et al., 2022).

Estas tecnologías permiten a los agricultores aumentar el rendimiento; hacer el análisis del suelo; controlar el ataque de plagas y enfermedades; el manejo de suelo y agua; la gestión de semillas; la rotación de cultivos; el momento de la cosecha; el manejo de la nutrición y la reducción de los desechos de biomasa.

La IA ha revolucionado la tecnología de la información y moldeado la forma en que vivimos. La IA es un modelo computacional que permite a las computadoras aprender de los datos y soluciones aproximadas para funciones complejas. Debido a su flexibilidad y robustez, la IA se ha aplicado en campos agrícolas a gran escala, empleando desde la robótica hasta el control del vuelo de aviones.

Elbeltagi et al. (2022) analizaron los avances de la IA en aspectos aplicados como la hidrología, agronomía, meteorología, atención médica, agricultura de precisión y más. Se enfoca en aplicaciones de la IA relacionadas con el manejo del agua y el suelo y afirma que la IA logra un alto rendimiento, precisión y correlación con bajos errores estadísticos, siendo por eso una herramienta de decisión rápida en condiciones climáticas cambiantes. Además, señala cómo la IA ayudará a los tomadores de decisiones y a los administradores del agua y suelo a alcanzar la sustentabilidad agrícola.

Las aplicaciones “inteligentes” impulsadas por la IA se han convertido en disruptores de la vida diaria. Al aprovechar el poder de los algoritmos de IA y el análisis de big data, las empresas de agua pueden maximizar la información y los datos disponibles para tomar las mejores decisiones, al tiempo que logran optimizar la prestación de servicios y reducen los costos.

El trabajo de Hubert et al. (2022) presenta los principios de la IA para las empresas de agua que se embarcan en esta transformación digital para mejorar su operación de distribución hídrica y describe algunas de las aplicaciones más extendidas del análisis de big data y los algoritmos relacionados con la IA en el suministro de agua, además, analiza cómo las empresas pueden emplear la IA para el pronóstico de la demanda y aportación de agua, presentando algunas recomendaciones para la implementación y estimaciones preliminares de costos.

La industria agrícola del siglo XXI está presenciando los impactos negativos del cambio climático, la escasez de tierra y agua y, más recientemente, la pandemia global del COVID-19. En consecuencia, la sustentabilidad socioeconómica de los sistemas de

suministro de alimentos actuales y futuros parece estar amenazada.

Para combatir los problemas debido a la escasez de agua en las granjas agrícolas, las soluciones basadas en IA están apareciendo como alternativas viables. Srivastava et al. (2022) argumentan que los potenciales usos de la IA se orientan principalmente en un contexto de manejo sustentable del agua y nutrientes, apoyadas por aplicaciones agrícolas emergentes de redes neuronales artificiales, aprendizaje automático, aprendizaje profundo, detección remota, procesamiento de imágenes digitales y a robótica.

A partir de resultados obtenidos ya se han identificado oportunidades para brindar el apoyo en tiempo real durante desastres naturales y se puede hacer el análisis de precios de los agromercados. También usando sensores e IA se ha logrado detectar el estado hídrico del cultivo para suministrar el agua transpirada (Figura 6).



Figura 6. La aplicación del riego usando inteligencia artificial integrada a un sistema de riego por goteo u otros sistemas presurizados, permite dosificar el volumen de riego por aplicar diariamente (Tomado de: <http://www.aiwatering.com/en/index.php>).

LA INTELIGENCIA ARTIFICIAL EN FITOPLAGAS

Las plagas y enfermedades de las plantas son grandes problemas en la agricultura ya que causan pérdidas de rendimiento y amenazan la seguridad alimentaria. Ha habido muchos esfuerzos para educar, proporcionar servicios y herramientas que ayuden a los agricultores a lidiar con el problema de las plagas y enfermedades.

Las aplicaciones móviles que utilizan IA son una de esas herramientas que se están explorando para que los agricultores identifiquen enfermedades (Sibanda et al., 2021). Hay evidencia de aplicaciones móviles que utilizan IA en las tiendas de aplicaciones móviles; sin embargo, hay escasez de estudios que muestren cómo los perciben los usuarios.

El estudio de Hariharan et al. (2023) presenta un método novedoso que utiliza un conjunto de datos para extraer la reflectancia de plantas. Estos datos obtenidos con

sensores de imágenes hiperespectrales se usan para desarrollar biomarcadores para la identificación de plantas y la detección temprana de enfermedades.

Las tecnologías para el control de plagas y enfermedades incluyen visión artificial e imágenes, trampas, extracción de datos, resonancia magnética nuclear, análisis de ADN, manejo de suelos y agua, señales vibratorias, fumigación de precisión y control de aves. Debido a eso, Lee y Tardaguila (2023) desarrollaron algunas tecnologías como la predicción de infestaciones de plagas mediante IA (Figura 7) y su identificación con aplicaciones para teléfonos inteligentes; sin embargo, aún se necesitarán más avances.

Las tecnologías usadas para la detección y manejo de enfermedades de las plantas incluyen visión por computadora, termografía, espectroscopia, fluorescencia de clorofila, imágenes hiperespectrales, compuestos orgánicos volátiles de plantas, biosensores, plataformas y robots de detección e inteligencia artificial.




Figura 7. Las soluciones de visión artificial y aprendizaje automático ofrecen grandes oportunidades para el reconocimiento automático de plantas enfermas mediante la inspección visual de las hojas dañadas, lo que reduce el tiempo de inspección (Tomado de: <https://bitrefine.group/industries/precision-agriculture/88-industries/agriculture-food/agriculture-solutions/184-plant-disease-detection>).

El estudio de Umamaheswari et al. (2023) investigó las enfermedades comunes en las hojas de tomate, para lo cual se utilizó un método basado en FC-SNDPN (Fully Convolutional – Switchable Normalization Dual Path Networks), para identificar y detectar automáticamente enfermedades foliares. La identificación de enfermedades de cultivos y plagas de insectos, dependen en gran medida de la obtención de características artificiales y tienen una capacidad deficiente para el reconocimiento de imágenes con un fondo complejo.

Para reducir la influencia del fondo complicado en el reconocimiento de imágenes de enfermedades de cultivos y plagas de insectos, se utilizó un algoritmo de red convolucional completa (FCN) basado en el modelo VGG-16 para segmentar la imagen de cultivo. Este

estudio ayudó a desarrollar una solución al problema y además, reduce el daño a los cultivos y frutas al identificar y erradicar las plagas desde las etapas tempranas del cultivo.

Los agricultores tienen dificultades para identificar diversas plagas y enfermedades de las plantas. El desarrollo reciente de la IA y técnicas de aprendizaje profundo se usan en el diagnóstico de enfermedades y plagas, proporcionando una herramienta robusta con resultados altamente precisos. En este contexto, el artículo de Omer et al. (2023) presenta el estado del arte sobre el uso de redes neuronales convolucionales (CNN) en el proceso de diagnóstico e identificación de plagas y enfermedades de las plantas.

Además, presenta algunos problemas a los que se enfrenta el rendimiento de los modelos y también indica lagunas que deben abordarse en el futuro, así que ahora es posible comprender las tendencias innovadoras con respecto al uso de los algoritmos de CNN en el diagnóstico de enfermedades de las plantas y reconocer las brechas que necesitan la atención de la comunidad de investigadores.

Las anomalías y las plagas de los cultivos han sido diagnosticados por expertos humanos, pero eso es costoso y consume mucho tiempo. Chithambarathanu y Jeyakumar (2023) hicieron una descripción de una investigación para identificación de plagas y patógenos de cultivos utilizando técnicas de aprendizaje automático como Random Forest (RF), Support Vector Machine (SVM) y Decision Tree (DT).

También presentaron métodos de aprendizaje profundo como la red neuronal convolucional, la memoria a largo y corto plazo, la red neuronal convolucional profunda y la red de creencias profundas. Según estos autores la estrategia descrita aumenta la productividad de los cultivos al tiempo que proporciona el más alto nivel de protección de los mismos.

La detección manual de plagas y enfermedades de las plantas es un proceso lento y propenso a errores, pudiendo ser un método poco confiable para identificar y prevenir la propagación de fitoenfermedades. Debido a eso, la adopción de tecnologías avanzadas como Machine Learning (ML) y Deep Learning (DL) pueden ayudar a superar estos desafíos al permitir la identificación temprana de fitoenfermedades.

En el artículo de Shoaib et al. (2023), se exploran los avances recientes en el uso de técnicas ML y DL para la identificación de enfermedades de las plantas, ya que proporciona información valiosa para los investigadores y profesionales de la detección de plagas y enfermedades al ofrecer soluciones y limitaciones a estos desafíos, brindando una comprensión integral del estado actual de la investigación, destacando los beneficios y restricciones de estos métodos, así como proponiendo posibles soluciones para superar los desafíos para su implementación.

INTELIGENCIA ARTIFICIAL PARA DIAGNOSTICO NUTRICIONAL DE CULTIVOS

La deficiencia de macronutrientes inhibe el crecimiento y desarrollo de las plantas de Chile. Uno de los métodos no destructivos que desempeña una función en el procesamiento de datos de imágenes de plantas con base a las características específicas, es la visión artificial. El estudio de Rahadiyan et al. (2023) utiliza datos de imágenes combinando tres tipos de características con HSV y RGB para color, GLCM y LBP para textura, y momentos Hu y distancia centroide para formas.

Los recientes hallazgos de Falcioni et al. (2023) tienen implicaciones importantes para el desarrollo de métodos eficientes para caracterizar el fenotipo vegetal y la concentración de nutrientes y metabolitos secundarios en diversas plantas y en las de lechuga (Figura 8), así como el potencial de la IA, los algoritmos y la tecnología hiperespectral para avanzar en la comprensión de sus capacidades en la agricultura de precisión para contribuir a un manejo agrícola más eficaz y sustentable.



Figura 8. Plantas de *Lactuca sativa* con variación de pigmentos asociados al contenido de clorofilas, carotenoides, antocianinas, flavonoides y fenoles. En círculos se muestran once variedades diferentes con variaciones de izquierda a derecha y de arriba a abajo (Tomado de: Falcioni et al., 2023).

Por su parte, el artículo de Thorat et al. (2023) presenta un modelo matemático que combina dos aspectos principales en la agricultura: identificación de plagas utilizando visión artificial y CNN. En segundo lugar, el análisis de nutrientes del suelo utiliza un sensor NPK con la recomendación de fertilizantes de acuerdo con los valores de nutrientes obtenidos.

Con esto se obtienen resultados en el lugar y el tiempo requerido para poder hacer la recomendación, que para el caso de insecticidas se requieren 10 s, y para la recomendación de fertilizantes son 80 s. La identificación exitosa de cinco plagas: áfidos, gusanos cogolleros, carpeta de hojas, minador de hojas y chinche apestosa verde, se realizó con más del 90% de precisión.

Este estudio analiza la combinación de características para identificar la deficiencia de macronutrientes. Se concluyó que el algoritmo analiza la combinación de características para identificar la deficiencia de macronutrientes; proporciona el resultado de combinar tres características utilizando el estudio propuesto y el estudio previo. Además, este trabajo agrega el nuevo desafío de la identificación de deficiencias de nutrientes y su aplicación en el entorno agrícola (Figura 9).



Figura 9. Las imágenes recopiladas por drones permiten determinar de manera más eficiente el color de las hojas de cultivos para así poder emitir un diagnóstico del estado nutricional del mismo (Tomado de: <https://dynamics.folio3.com/blog/artificial-intelligence-in-agriculture/>).

La dieta es una de las principales razones vitales que afectan la vida humana, pero el mercado abunda en productos agrícolas tratados con pesticidas y fertilizantes, lo que pone en riesgo la salud humana. El trabajo de Amkor y El Barbri (2023) tuvo como objetivo predecir el comportamiento fisiológico de la papa (*Solanum tuberosum*) fertilizada orgánicamente o con fertilizantes químicos tradicionales.

Los datos fueron recolectados por una tarjeta de adquisición de datos de un conjunto de sensores fabricados con cinco de gas de óxido de metal (MOX). Las respuestas de los sensores se utilizaron para evaluar la precisión de la clasificación y la predicción. Los autores insinúan en sus conclusiones que tienen una herramienta capaz de identificar y

predecir si las papas cosechadas fueron tratadas con fertilizante NPK o con fertilizante orgánico de ovejas y burros.

La agricultura es el pilar de la economía en muchos países del mundo, pero factores como el cambio climático, el crecimiento de la población y la seguridad alimentaria impulsan a la industria agroalimentaria a buscar enfoques innovadores para mejorar el rendimiento de los cultivos. Debido a eso, la IA emerge como parte esencial de la evolución tecnológica de la agroindustria.

En la actualidad, el sistema integrado de manejo y control del riego y fertilizantes ha cumplido con los requisitos de control automático de estos insumos, transformando gradualmente la operación manual tradicional. Sin embargo, según Li et al. (2023) este método tiene un uso débil de datos y todavía hay una gran brecha entre el método de cálculo y el control inteligente.

Tomando el repollo de invernadero como el principal objeto de investigación, en función de los parámetros ambientales del cultivo, los parámetros morfológicos de crecimiento, los requisitos riego y fertilizantes durante el período de crecimiento del repollo, se propuso el establecimiento de un modelo inteligente de manejo y control para la toma de decisiones sobre los insumos agua y fertilizantes.

Los resultados mostraron que el error de predicción del modelo de riego con toma de decisiones inteligentes para agua y fertilizantes para repollo de invernadero fue relativamente pequeño, y la relación de acoplamiento entre datos de múltiples fuentes y la toma de decisiones del modelo se mejora a través de la extracción de múltiples características.

El crecimiento de la IA en el mundo impulsa algunos aspectos destacados en las ciencias agrícolas para ayudar a los agricultores con buena información agrícola. Acode con Ibrahimpatnam et al. (2021), Machine Learning Techniques (MLT) desarrolla un modelo bien definido con los datos y ayuda a lograr predicciones acertadas.

Cuestiones agrícolas como la rotación de cultivos, el requerimiento de agua y fertilizantes, así como la protección contra plagas se pueden resolver con IA. Debido a los factores climáticos variables del entorno, existe la necesidad de contar con una técnica eficiente como la IA para facilitar el manejo de los cultivos y dar una mano a los agricultores en la producción de alimentos.

El manejo de cultivos agrícolas incluye una vigilancia muy estrecha, en particular con respecto al tratamiento de enfermedades y la deficiencia de agua y nutrientes. Uikay et al. (2023) argumentan que las enfermedades y las deficiencias se reconocen por cambio de colores y síntomas que las plantas muestran. La mayoría de los síntomas que los agentes

patógenos causan se observan en las hojas, tallos y ramas de los cultivos.

Esto se puede lograr tomando imágenes con una cámara instalada en un dron y analizando los datos usando el proceso de aprendizaje automático. El movimiento del robot se realiza con un controlador de motor L293d y el procesador o sistema integrado es hecho a través de Raspberry pi3. Los autores usaron el código python para el aprendizaje automático que entrena al robot con imágenes predefinidas. Debido a que esto se puede controlar desde cualquier lugar sin trabajar en el campo y estar expuesto a plaguicidas, los autores señalan que la IA es un beneficio para los agricultores, ya que no se verán afectados en su estado de salud.

INTELIGENCIA ARTIFICIAL PARA EL MANEJO Y COSECHA DE CULTIVOS

La habilidad de predecir la producción de cultivos se realiza antes de la cosecha. Los pronósticos de producción de cultivos ayudan a las personas a hacer juicios oportunos sobre los precios en los mercados, las leyes de importación y exportación y el almacenamiento durante poscosecha.

Es posible reducir los efectos socioeconómicos de la pérdida de cultivos provocada por un desastre natural, como una inundación o una sequía, y organizar la asistencia alimentaria humanitaria. Bharadiya et al. (2023) han sugerido que el aprendizaje profundo, permite que automáticamente un modelo matemático o algoritmo obtenga las características de los conjuntos de datos, lo cual podría ser útil para predecir el momento de la cosecha y los rendimientos agrícolas.

Estos autores realizaron un estudio que se centró en los beneficios del aprendizaje automático, los factores agrícolas y la teledetección para pronosticar el rendimiento de los cultivos. La forma de teledetección empleada con más frecuencia es la tecnología satelital, es decir, el uso del radiómetro de espectro de imágenes de resolución moderada. Los índices de vegetación se refieren como el atributo más empleado para pronosticar el rendimiento de los cultivos.

La IA en el sector agrícola ofrece el potencial para alimentar a una población mundial en continuo crecimiento y seguir contribuyendo a alcanzar los Objetivos de Desarrollo Sostenible (ODS) de la ONU. A pesar de sus promesas, el uso de la IA en la agricultura aún es limitado. Se argumenta que su lenta adopción se debe a las diversas formas en que la IA impacta en la industria agroalimentaria, debido a la diversidad de alimentos, cadenas de suministro, climas y tipo de tierra agrícola.

El reporte de Zhou et al. (2023) menciona que la cosecha de tomates puede ser automatizada con robots (Figura 10), además su clasificación y el transporte de los frutos

incluye la clasificación de los productos defectuosos, su clasificación en categorías según la calidad, su distribución en contenedores y su transporte a las estaciones de recolección en el campo.

Se argumenta que los avances de la IA pueden acelerar la clasificación y el transporte desde la granja, siendo esto con alta precisión y robustez, reduciendo así significativamente las pérdidas poscosecha.




Figura 10. La modernización de la cosecha mediante la inteligencia artificial permite realizar los cortes de tomates acorde a su grado de madurez usando robots que manipulan una gran cantidad de información almacenada y procesada en computadoras, tabletas y teléfonos inteligentes; sin embargo, esto elimina una gran cantidad de mano de obra. (Tomado de: <https://www.phytoma.com/noticias/noticias-de-actualidad/agraria-investiga-el-uso-de-la-inteligencia-artificial-en-el-sector-agroalimentario>).

El artículo de Ryan et al. (2023) señala que la falta de adaptación de la IA por los productores se ve exacerbado por las preocupaciones éticas que surgen por el uso de la IA, los diversos grados de desarrollo tecnológico y habilidades, y los impactos económicos de la IA. Los sistemas impulsados por IA en la agricultura plantean varios conjuntos de preocupaciones en múltiples disciplinas que deben alinearse para proporcionar soluciones sustentables de IA para el dominio de la agricultura.

El procesamiento de alimentos poscosecha requiere una amplia gama de nuevas técnicas emergentes para una producción y manipulación eficiente de los alimentos. Entre estos, la IA está captando la atención de las empresas en muchas disciplinas y sectores directa e indirectamente, ya que no solo analiza los datos digitalmente, sino que también reemplaza con precisión la mayoría de las intervenciones humanas (Tiwari et al., 2023).

Cultivos hortícolas de hoja para consumo en fresco como las lechugas (*Lactuca sativa*) cultivadas a cielo abierto, requieren mucha mano de obra, resultando costosa la operación de la cosecha, clasificación y empackado (Figura 11). Debido a eso la IA se convierte en una herramienta poderosa para apoyar la reducción de los costos operativos de este cultivo y para aumentar su productividad.



Figura 11. La cosecha automatizada de hortalizas ha sido testigo de algunos de los mayores avances tecnológicos como la inteligencia artificial. La cosecha de la lechuga iceberg requiere mucha mano de obra y al crecer cerca del suelo, puede dañarse, lo que representa un desafío para la cosecha con personal de campo. (Tomado de: <https://agroempresario.com/publicacion/6275/vegebot-el-robot-entrenado-capaz-de-recolectar-lechugas/?cat=121>)

Aunque la agricultura sigue siendo la actividad económica dominante en muchos países del mundo, en los últimos años este sector ha seguido viéndose afectado negativamente por el nefasto cambio climático, lo que ha provocado inseguridad alimentaria. Esto es así porque las condiciones climáticas extremas inducidas por el cambio climático son perjudiciales para la mayoría de los cultivos y afectan la cantidad esperada de producción agrícola (Okolie et al., 2023).

El intercambio temprano de información sobre la producción agrícola esperada puede ayudar a reducir el riesgo de inseguridad alimentaria. En este sentido, el trabajo de Kuradusenge et al. (2023) emplea técnicas de minería de datos para predecir cosechas futuras de cultivos (papas irlandesas y maíz) utilizando datos históricos de rendimiento y clima. El estudio también aplica técnicas de aprendizaje automático para predecir las cosechas de cultivos en función de los datos meteorológicos y comunicar la información sobre las tendencias de producción.

En este sentido, los autores emplearon técnicas de minería de datos para predecir cosechas futuras de los cultivos de papas irlandesas y maíz. Los datos recopilados se analizaron mediante Random Forest, Polynomial Regression y Support Vector Regressor. Los resultados indicaron que Random Forest fue el mejor modelo con un error cuadrático

medio de 510.8 y 129.9 para papa y maíz respectivamente.

INTELIGENCIA ARTIFICIAL PARA EL MANEJO DE INVERNADEROS

La mayor demanda de tierras agrícolas y la ocurrencia más frecuente de condiciones climáticas extremas conducen a un mayor uso de invernaderos en la agricultura. Los invernaderos de alta tecnología ofrecen una alternativa eficiente a la agricultura tradicional ya que todos los parámetros ambientales están controlados, lo que conlleva a un mayor rendimiento por uso de la tierra. El cambio climático ya ha demostrado su terrible efecto sobre la agricultura.

El intercambio temprano de información sobre la producción agrícola esperada puede ayudar a reducir el riesgo de la inseguridad alimentaria. En este sentido, el trabajo de Kuradusenge et al. (2023) emplea técnicas de minería de datos para predecir cosechas futuras de los cultivos de papas y maíz. Por su parte, Soheli et al. (2023) reportan que, en comparación con otros sistemas propuestos y disponibles, este tipo de invernadero también combina la tecnología IoT para identificar amenazas de datos en una transferencia de red con conjunto difuso.

Este enfoque mejora la eficiencia del aprendizaje, la precisión de la predicción y demostró ser un sistema automatizado de mantenimiento de invernaderos factible y eficaz. El módulo de recopilación de datos, así como el módulo del subsistema de seguridad, logran tener el almacenamiento de datos en la nube. Dado que los invernaderos se están adoptando ampliamente en todo el mundo, es importante mejorar la eficiencia energética de los sistemas de control mientras se regula con precisión su clima interior para realizar prácticas agrícolas sustentables para la producción de alimentos.

En la información de Ajagekar et al. (2023) se propuso un sistema de control basado en IA que combina técnicas de aprendizaje de refuerzo profundo para generar conocimientos sobre el funcionamiento del invernadero combinado con una optimización robusta para producir controles energéticamente eficientes al protegerse contra las incertidumbres asociadas.

El estudio señala que: 1) Se desarrolló una estrategia de aprendizaje de refuerzo profundo para estimar el uso de energía. 2) Se aprovecha la optimización robusta para obtener controles mediante la cobertura contra la incertidumbre. 3) El controlador propuesto mantiene el clima del invernadero de manera muy eficiente.

Debido que con la IA aplicada a los drones se pueden obtener fácilmente datos en tiempo real, estos aparatos tienen un gran potencial para encontrar soluciones a los problemas que enfrenta la agricultura. Aslan et al. (2022) mencionan que, a pesar de

algunas limitaciones, como la batería, la carga, las condiciones climáticas, etc., los drones se utilizarán en la agricultura del futuro debido a los valiosos datos que obtienen con sus cámaras (Figura 12) y sus eficientes aplicaciones en: fumigación, monitoreo, estimación de rendimiento, detección de malezas, etc.

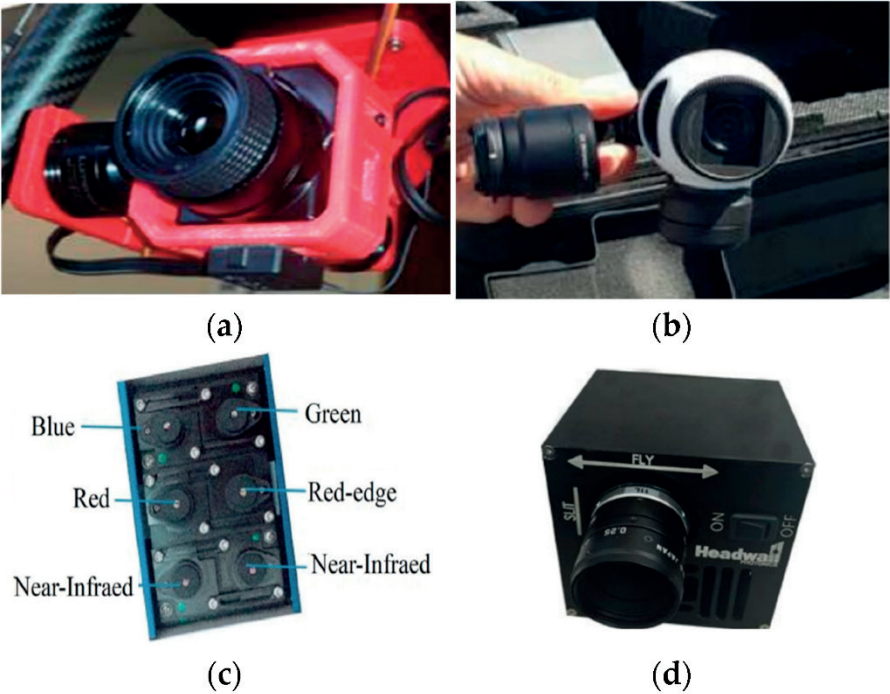


Figura 12. Tipos de cámaras utilizadas en aplicaciones agrícolas de vehículos aéreos no tripulados (drones). (a) Cámara térmica. (b) Cámara RGB. (c) Cámara multiespectral y (d) Cámara hiperespectral (Tomado de: Aslan et al., 2022).

Por supuesto, será necesario monitorear las primeras aplicaciones, proporcionar a los algoritmos un conjunto de datos más amplio y mejorar su rendimiento, pero estos sistemas ya pueden ingresar al mercado e integrarse en invernaderos de tipo holandés (Gu et al., 2022).

El estudio de Ahmad et al. (2023) señala que el sistema inteligente de monitoreo del invernadero funcionó mejor para mantener el microclima dentro del mismo con una diferencia de 5 - 6°C de temperatura y 20-30% de humedad más alta que el invernadero convencional. Los resultados con el cultivo de tomate predijeron un aumento progresivo de parámetros agronómicos con una diferencia de 10 - 15% en la altura de la planta, número de hojas, número y peso de los frutos; esto en comparación con parámetros de crecimiento en un invernadero convencional.

Ariesen-Verschuur et al. (2023) revisaron cómo Digital Twins puede mejorar la

horticultura de un invernadero inteligente basado en datos. El documento publicado describe el estado del arte de las aplicaciones Digital Twin que ya se aplican en los sistemas inteligentes basados en IoT, permitiendo el control del clima, además supervisa y controla factores ambientales, por lo que en el entorno de la IA agrícola y los gemelos digitales predictivos están emergiendo rápidamente.

Los Digital Twins o gemelos digitales (Figura 13) son versiones virtuales de organismos y objetos vivos y no vivos, como células, plantas, animales, seres humanos, ecosistemas y diversos objetos inanimados, como motores, cadenas alimentarias y de suministro. Con los proyectos Digital Twin, la IA se está posicionando para lograr importantes avances científicos y sociales.



Figura 13. Los gemelos digitales se usan para describir, analizar y simular procesos y organismos a través de la integración de datos, la inteligencia artificial y el aprendizaje automático. Esto no solo permite comprender, describir y analizar mejor la realidad, sino que también permite predecir el futuro de estos objetos o plantas con mayor precisión (Tomado de: <https://www.wur.nl/en/research-results/research-programmes/research-investment-programmes/digital-twins.htm>).

El rápido aumento de la demanda de agua debido al crecimiento de la población y del sector agrícola que consume enormes cantidades de agua, se están viendo amenazadas las reservas hídricas superficiales y subterráneas. Para lograr superar este reto, Mokhtari et al. (2023) consideran que se necesita desarrollar sistemas de riego para reducir y optimizar el uso de agua y energía. Además, la orientación a la automatización de estos sistemas puede mejorar la productividad, aumentar la eficiencia del riego y reducir los costos de mano de obra.

El desarrollo de la agricultura protegida es la única forma en que China puede realizar la modernización agrícola. Los invernaderos en China se han establecido ampliamente, pero su grado de automatización no es alto. Chen y Hu (2022) señalan que los algoritmos inteligentes generados en los últimos años no se basan en información de gradientes y otros conocimientos auxiliares, sino que son adecuados para resolver problemas reales y complejos a gran escala.

Por lo tanto, se introdujeron los conceptos relacionados con el algoritmo genético mejorado y se diseñó un sistema de control de invernaderos. Los resultados muestran que, a través del control inteligente la desviación de la temperatura del aire es inferior a 0.5°C y la desviación de la humedad del aire (HR) es inferior al 1%. El valor de la concentración de dióxido de carbono después de ser básicamente estable tiene pequeñas fluctuaciones inferiores al 2.5%.

La mayor demanda de tierras agrícolas y la ocurrencia más frecuente de condiciones climáticas extremas debido al calentamiento global, conducen a un mayor uso de invernaderos, ya que ofrecen una alternativa eficiente a la agricultura tradicional la agricultura de cielo abierto porque todos los parámetros ambientales están controlados, lo que implica un mayor rendimiento y seguridad alimentaria. En los invernaderos antiguos o modernos, pero de baja tecnología, los parámetros ambientales se configuran manualmente, lo que resultaba en condiciones climáticas desfavorables debido a los excesos y deficiencias de factores bióticos y abióticos.

Los sensores del invernadero responden a varios valores de entrada que provocan cambios en los parámetros ambientales (Walczuch et al., 2022). Para controlar los sensores, la IA ofrece el potencial de vigilar los parámetros ambientales con mayor precisión. Con la posibilidad de predecir la influencia de los sensores con respecto al clima del invernadero, los sistemas climáticos basados en IA podrían superar a los sistemas tradicionales y a los expertos humanos.

El agua de riego también puede ser aplicada a las plantas cuando algunos sensores instalados en el suelo, sustrato o tejido de las plantas, emitan una señal indicando que el nivel del agua en las plantas (Figura 14) se encuentra en un determinado potencial hídrico, y, por lo tanto, ya se requiere aplicar un volumen de riego durante una cierta cantidad de tiempo en minutos u horas.

Dentro de la industria automotriz, hay esfuerzos para reemplazar los compuestos de polímeros y fibra de vidrio por fibras naturales más ecológicas pero livianas, ya que podrían reducir los impactos ambientales. Para saber si estos reemplazos son más amigables con el ambiente y cuánto reducen las emisiones dentro del ciclo de vida del vehículo, el

estándar de oro es una evaluación del ciclo de vida (LCA) basada en las emisiones de gases de efecto invernadero.



Figura 14. Sensores instalados en el microambiente de las plantas emiten señales que son enviadas a brazos robóticos para que se aplique el riego con nutrientes. (Tomado de: <https://www.intel.la/content/www/xl/es/partner/showcase/accenture/overview.html>).

La LCA es una herramienta valiosa. Sin embargo, Akhshik et al. (2022) reportan que este método requiere mucho tiempo, teniendo que abordar demasiados detalles y podría ser complicado de ejecutar. Por eso, la IA puede ser una disciplina muy promisoría que puede predecir fácilmente una consulta complicada mediante datos.

Pero datos limitados generalmente disuaden a los investigadores, sin embargo, nos permite probar varios algoritmos de IA y matrices de entrada para predecir rápidamente las emisiones de gases de efecto invernadero basadas en LCA. A pesar de que este método no es convencional y necesita más evaluaciones, está mostrando una manera muy prometedora y fácil para predecir con precisión la reducción de gases de efecto invernadero.

Respecto de la inseguridad alimentaria universal, se prevé que más del 60% de los países subsaharianos se encuentren en estado de desnutrición y, además, varios distritos agrícolas se encuentran en estado de sequía. Debido a esto, el uso de un invernadero moderno con IA para cultivar y proteger plantas en estaciones secas y húmedas, para reducir la mano de obra y automatizar el análisis de datos del estado diario de las plantas, puede aumentar notablemente la seguridad alimentaria.

Al implementar un enfoque de visión por computadora basado en redes neuronales, se pudo realizar un seguimiento del estado de salud de las plantas causado por varios

microorganismos. Las predicciones y los resultados obtenidos verifican con precisión cómo se puede utilizar el aprendizaje automático para aumentar la seguridad alimentaria mediante la implementación de sistemas de IA en múltiples áreas agrícolas sin la participación humana previa.

Por su parte, el reporte de Farooqui et al. (2022) presenta un sistema de invernadero completamente automatizado con IA integrada, el cual utiliza alrededor de 10,000 imágenes de plantas (Figura 15) obtenidas de todo el invernadero en condiciones atmosféricas óptimas, tomando decisiones en tiempo real, detectando cualquier tipo de enfermedad, plagas, deficiencias de nutrientes e informando la etapa fenológica del cultivo y sobre todo la madurez de la fruta.



Figura 15. Un invernadero completamente automatizado con inteligencia artificial integrada utiliza muchas imágenes de plantas en condiciones óptimas tomando decisiones en tiempo real, detectando cualquier deficiencia y/o falta de agua, así como el tipo de plaga o enfermedad que se pueda presentar y afecte el cultivo. (Tomado de: <https://depositphotos.com/es/photos/trazabilidad-de-alimentos.html>).

Maraveas et al. (2022) en su reporte señalan que la modernización agrícola implica aplicar tecnología de IA en invernaderos inteligentes para optimizar el rendimiento de los cultivos, la eficiencia en el uso del agua y los fertilizantes, reducir las plagas y enfermedades y mejorar la sostenibilidad agrícola.

Las tecnologías clave fueron los sistemas robóticos para la aplicación de pesticidas, el riego, la cosecha, los algoritmos bioinspirados para la automatización de procesos de invernadero, el manejo de energía eléctrica, la planificación de rutas de máquinas y la operación de drones para la resolución de problemas de programación y la obtención de

imágenes.

La IA en la agricultura se apoya con drones aéreos, sensores eléctricos, visuales, olfativos y biológicos, con toda la información disponible crea archivos de análisis según lo que se necesite saber. Combina la información de los sistemas de posición geográfica y de genética. En los grandes cultivos, estas máquinas son capaces de monitorear plagas que invaden las plantaciones, incluso se crearon maquinas inteligentes llamadas ciber-insectos (Figura 16).




Figura 16. Los ciber-insectos han sido desarrollados en Japón para ayudar a realizar reconocimientos en zonas inaccesibles, peligrosas o agrícolas para comprobar las condiciones ambientales y edáficas de las extensiones de tierra cultivada. (Tomado de: <https://www.ibsafoundation.org/en/blog/cyborg-beetles>).

El trabajo de Choubisa y Doshi (2022) señala que los ciber-insectos son drones que se pueden controlar mediante jaulas móviles eléctricas. En este trabajo se enfocaron en cosechar pimienta dulce y mostrar la ingeniería tecnológica necesaria para realizar la operación de cosecha (Figura 17).

Esta tarea comienza con el control de la robótica aérea y la planificación de la trayectoria, combinados con la detección de pimientos basada en el aprendizaje profundo, un enfoque de agrupación para la estimación del rendimiento y la planificación de la misión para la cosecha utilizando un equipo heterogéneo de robots.




Figura 17. Cosecha robotizada de pimientos maduros utilizando inteligencia artificial, esto permite hacer una discriminación muy detallada de los frutos que se habrán de obtener en cada corte, hasta el final de la cosecha dentro del invernadero. (Tomado de: <https://www.agritotal.com/nota/el-robot-que-cosecha-pimientos/>).

CONCLUSIONES

Definitivamente que la inteligencia artificial (IA) ayudará a la producción de hortalizas y todo tipo de cultivos de alta calidad y altos rendimientos, siendo mas sustentable por el menor uso de mano de obra e insumos, además se reducen los daños causados a los operarios por la menor inhalación e ingestión de agroquímicos, cuando estas labores son realizadas por robots y aspersores inteligentes.

La aplicación práctica de los sistemas de IA ya se está dando en muchas partes del mundo, muchos algoritmos desarrollados se están ofreciendo en el mercado para apoyar a la agricultura protegida y la practicada en campo abierto. Esto abre la posibilidad de un gran nicho de negocios que permite a los productores de hortalizas y/o flores en invernaderos, a conocer precios, oportunidades de mercado por Internet y por proveedores de IoT.

A medida que la tecnología continúa evolucionando, se hace patente que el potencial de la IA en la agricultura es inmenso. Al desbloquear el poder de la IA, los agricultores pueden obtener acceso a una variedad de información basada en datos obtenidos en tiempo real, esto les permite tomar decisiones más informadas para optimizar las operaciones del paquete tecnológico agronómico aplicado a su cultivo.

Esto permitirá a los agricultores a hacer un manejo sustentable de los agroinsumos

en los cultivos, a la vez que pueden incrementar rendimientos, reducir costos, y administrar mejor sus recursos naturales y agroinsumos. Además, la IA puede ayudar a reducir el desperdicio de alimentos, mejorar la seguridad alimentaria y crear prácticas de cultivo sustentables.

Estamos seguros que con el paso de los años la demanda y la competencia por la calidad y sanidad de los productos agrícolas hará que los productores opten por mejorar y adentrarse al mundo de la IA para optimizar operaciones, reducir costos y producir nuestros alimentos de manera ecológica.

LITERATURA CITADA

- Ahmad, B., Ahmed, R., Masroor, S., Mahmood, B., Hasan, S.Z.U., Jamil, M. y Tariq, S. (2023). Evaluation of smart greenhouse monitoring system using raspberry-pi microcontroller for the production of tomato crop. *Journal of Applied Research in Plant Sciences*, 4(01), 452-458.
- Ajagekar, A., Mattson, N. S. y You, F. (2023). Energy-efficient AI-based control of semi-closed greenhouses leveraging robust optimization in deep reinforcement learning. *Advances in Applied Energy*, 9, 100119.
- Akhshik, M., Bilton, A., Tjong, J., Singh, C.V., Faruk, O. y Sain, M. (2022). Prediction of greenhouse gas emissions reductions via machine learning algorithms: Toward an artificial intelligence-based life cycle assessment for automotive lightweighting. *Sustainable Materials and Technologies*, 31, e00370.
- Amkor, A. y El Barbri, N. (2023). Artificial intelligence methods for classification and prediction of potatoes harvested from fertilized soil based on a sensor array response. *Sensors and Actuators A: Physical*, 349, 114106.
- Ariesen-Verschuur, N., Verdouw, C. y Tekinerdogan, B. (2022). Digital twins in greenhouse horticulture: A review. *Computers and Electronics in Agriculture*, 199, 107183.
- Aslan, M.F., Durdu, A., Sabanci, K., Ropelewska, E. y Gültekin, S.S. (2022). A comprehensive survey of the recent studies with UAV for precision agriculture in open fields and greenhouses. *Applied Sciences*, 12(3), 1047.
- Bharadiya, J.P., Tzenios, N.T. y Reddy, M. (2023). Forecasting of crop yield using remote sensing data, agrarian factors and machine learning approaches. *Journal of Engineering Research and Reports*, 24(12), 29-44.
- Chen, Q. y Hu, X. (2022). Design of intelligent control system for agricultural greenhouses based on adaptive improved genetic algorithm for multi-energy supply system. *Energy Reports*, 8, 12126-12138.
- Chithambarathanu, M. y Jeyakumar, M.K. (2023). Survey on crop pest detection using deep learning and machine learning approaches. *Multimedia Tools and Applications*, 1-34.
- Choubisa, M. y Doshi, R. (2022). Crop protection using cyber physical systems and machine learning for smart agriculture. In *Real-Time Applications of Machine Learning in Cyber-Physical Systems* (pp. 134-147). IGI Global.
- Dharmaraj, V. y Vijayanand, C. (2018). Artificial intelligence (AI) in agriculture. *International Journal of Current Microbiology and Applied Sciences*, 7(12), 2122-2128.
- Elbeltagi, A., Kushwaha, N.L., Srivastava, A. y Zoof, A.T. (2022). Artificial intelligent-based water and soil management. In *Deep learning for sustainable agriculture* (pp. 129-142). Academic Press.
- Falcioni, R., Gonçalves, J.V.F., Oliveira, K.M.D., Oliveira, C.A.D., Demattê, J.A., Antunes, W.C. y Nanni, M.R. (2023). Enhancing pigment phenotyping and classification in lettuce through the integration of reflectance spectroscopy and AI algorithms. *Plants*, 12(6), 1333.

Farooqui, N.A., Mishra, A.K. y Mehra, R. (2022). IOT based automated greenhouse using machine learning approach. *International Journal of Intelligent Systems and Applications in Engineering*, 10(2), 226-231.

Ghatrehsamani, S., Jha, G., Dutta, W., Molaei, F., Nazrul, F., Fortin, M. y Neupane, J. (2023). Artificial intelligence tools and techniques to combat herbicide resistant weeds—A Review. *Sustainability*, 15(3), 1843.

Gu, Y., Zhao, L., Liu, Q. y Zhang, X. (2022, May). Design and research of intelligent agricultural greenhouse based on agricultural internet of things technology. In *International Conference on Biometrics, Microelectronic Sensors, and Artificial Intelligence (BMSAI)* (Vol. 12252, pp. 91-96). SPIE.

Güenal, E., Budak, M., Kılıç, M., Cemek, B. y Sirrı, M. (2023). Combining spatial autocorrelation with artificial intelligence models to estimate spatial distribution and risks of heavy metal pollution in agricultural soils. *Environmental Monitoring and Assessment*, 195(2), 317.

Hariharan, J., Ampatzidis, Y., Abdulridha, J. y Batuman, O. (2023). An AI-based spectral data analysis process for recognizing unique plant biomarkers and disease features. *Computers and Electronics in Agriculture*, 204, 107574.

Hubert, J., Garcia, A.E., Wang, Y., Minguez, R. (2020). Using artificial intelligence for smart water management systems. *Asian Development Bank*. <http://hdl.handle.net/11540/12225>.

Ibrahimpattam, H., Varma, S., Student, C.S y Siet, S. (2021). Crop and fertilizers recommendation and disease prediction using deep learning. *Dogo Rangasang Research Journal*. Vol-08 Issue-14 No. 03.

Jadav, N.K., Rathod, T., Gupta, R., Tanwar, S., Kumar, N. y Alkhayyat, A. (2023). Blockchain and artificial intelligence-empowered smart agriculture framework for maximizing human life expectancy. *Computers and Electrical Engineering*, 105, 108486.

Javaid, M., Haleem, A., Khan, I.H. y Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15-30.

Kalichkin, V., Koryakin, R.A. y Maksimovich, K. (2023, January). Connectivity conceptual modelling for plant agriculture artificial intelligence information systems. In *AIP Conference Proceedings* (Vol. 2643, No. 1, p. 040019). AIP Publishing LLC.

Kaur, G., Singh, B., Angrish, A.K. y Bansal, S.K. (2022). Artificial intelligence (AI) based smart agriculture for sustainable development. *The Management Accountant Journal*, 57(6), 54-57.

Krishnan, S.R., Nallakaruppan, M.K., Chengoden, R., Koppu, S., Iyapparaja, M., Sadhasivam, J. y Sethuraman, S. (2022). Smart water resource management using artificial intelligence—A Review. *Sustainability*, 14(20), 13384.

Kuradusenge, M., Hitimana, E., Hanyurwimfura, D., Rukundo, P., Mtonga, K., Mukasine, A. y Uwamahoro, A. (2023). Crop yield prediction using machine learning models: Case of Irish Potato and Maize. *Agriculture*, 13(1), 225.

Kutyauripo, I., Rushambwa, M. y Chiwazi, L. (2023). Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 100502.

Lee, W.S. y Tardaguila, J. (2023). Pest and disease management. In *Advanced Automation for Tree Fruit Orchards and Vineyards* (pp. 93-118). Cham: Springer International Publishing.

Li, S., Miao, Y., Han, X. y Guo, W. (2023, January). Research on intelligent decision-making irrigation model of water and fertilizer based on multi-source data input. In *Artificial Intelligence: Second CAAI International Conference, CICAII 2022, Beijing, China, August 27–28, 2022, Revised Selected Papers, Part II* (pp. 206-217). Cham: Springer Nature Switzerland.

Mana, A.A., Allouhi, A., Hamrani, A., Jamil, A., Barrahmoune, K.O.A. y Daffa, D. (2023). Survey review on artificial intelligence and embedded systems for agriculture safety: A proposed IoT agro-meteorology system for local farmers in Morocco. *Smart Embedded Systems and Applications*, 211.

Maraveas, C. (2022). Incorporating artificial intelligence technology in smart greenhouses: current state of the art. *Applied Sciences*, 13(1), 14.

Menaga, A. y Vasantha, S. (2022). Smart sustainable agriculture using machine learning and AI: A Review. *Ambient Communications and Computer Systems: Proceedings of RACCCS 2021*, 447-458.

Mokhtari, H., Benzaouia, M., Bekkay, H. y Chaabane, K. (2023, April). A review on precision irrigation techniques and controls for better water use efficiency in agriculture. In *Proceedings of the 3rd International Conference on Electronic Engineering and Renewable Energy Systems: ICEERE 2022, 20-22 May 2022, Saidia, Morocco* (pp. 707-716). Singapore: Springer Nature Singapore.

Okolie, C.C., Danso-Abbeam, G., Groupson-Paul, O. y Ogundeji, A.A. (2023). Climate-Smart agriculture amidst climate change to enhance agricultural production: A Bibliometric Analysis. *Land*, 12(1), 50.

Omer, S.M., Ghafoor, K.Z. y Askar, S.K. (2023). Plant disease diagnosing based on deep learning techniques. *Aro-The Scientific Journal of Koya University*, 11(1), 38-47.

Rahadiyan, D., Hartati, S. y Nugroho, A.P. (2023). Feature aggregation for nutrient deficiency identification in chili based on machine learning. *Artificial Intelligence in Agriculture*.

Riaz, M.W., Yousaf, M.I., Hussain, Q., Yasir, M., Sajjad, M. y Shah, L. (2023). Role of lignin in wheat plant for the enhancement of resistance against lodging and biotic and abiotic stresses. *Stresses*, 3(2), 434-453.

Ryan, M., Isakhanyan, G. y Tekinerdogan, B. (2023). An interdisciplinary approach to artificial intelligence in agriculture. *NJAS: Impact in Agricultural and Life Sciences*, 95(1), 2168568.

Saxena, R., Joshi, A., Joshi, S., Borkotoky, S., Singh, K., Rai, P.K. y Sharma, R. (2023). The role of artificial intelligence strategies to mitigate abiotic stress and climate change in crop production. In *Visualization Techniques for Climate Change with Machine Learning and Artificial Intelligence* (pp. 273-293). Elsevier.

Shoaib, M., Shah, B., Ei-Sappagh, S., Ali, A., Ullah, A., Alenezi, F. y Ali, F. (2023). An advanced deep learning models-based plant disease detection: A review of recent research. *Frontiers in Plant Science*, 14, 875.

Sibanda, B.K., Iyawa, G.E. y Gamundani, A.M. (2021, November). Mobile apps utilising AI for plant disease identification: A systematic review of user reviews. In *2021 3rd International Multidisciplinary Information Technology and Engineering Conference (IMITEC)* (pp. 1-6). IEEE.

Sirineni, H., Santosh, T. y Deepajothi, S. (2022). Artificial intelligence in agriculture: A Review. *Machine Learning for Business Analytics*, 87-95.

Soheli, S.J., Jahan, N., Hossain, M.B., Adhikary, A., Khan, A.R. y Wahiduzzaman, M. (2022). Smart greenhouse monitoring system using internet of things and artificial intelligence. *Wireless Personal Communications*, 124(4), 3603-3634.

Srivastava, A., Jain, S., Maity, R. y Desai, V.R. (2022). Demystifying artificial intelligence amidst sustainable agricultural water management. *Current Directions in Water Scarcity Research*, 7, 17-35.

Sudar, K.M., Nagaraj, P., Prakash, B., Reddy, M.M., Naidu, M.M. y Kumar, H. (2022, May). Development of tomato leaf disease prediction system to the farmers by using artificial intelligent network. In *2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS)* (pp. 955-961). IEEE.

Talaviya, T., Shah, D., Nivedita, P., Yagnik, H. y Shah, M., 2020. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides, *Artificial Intelligence in Agriculture* 4, 58-73

Tiwari, M., Pandey, H., Mukherjee, A. y Sutar, R.F. (2023). Artificial Intelligence in food processing. *Novel Technologies in Food Science*, 511-550.

Thorat, T., Patle, B.K. y Kashyap, S.K. (2023). Intelligent insecticide and fertilizer recommendation system based on TPF-CNN for smart farming. *Smart Agricultural Technology*, 3, 100114.

Umamaheswari, S., Vishal, N.R., Pragadesh, N.R. y Lavanya, S. (2023, March). Performance analysis of ResNet50 architecture based pest detection system. In *2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS)* (Vol. 1, pp. 578-583). IEEE.

Uikey, R.W., Rangari, R.P., Kewate, C.P., Polke, A.R., Titarmare, P. y Yende, S. (2023). A review on intelligent agricultural seed and fertilizer spreader robot with IOT. *International Research Journal of Modernization in Engineering Technology and Science*. Volume:05/Issue:01/January-2023.

Wakchaure, M., Patle, B.K. y Mahindrakar, A.K. (2023). Application of AI techniques and robotics in agriculture: A Review. *Artificial Intelligence in the Life Sciences*, 100057.

Walczuch, D., Nitzsche, T., Seidel, T. y Schoning, J. (2022, August). Overview of closed-loop control systems and artificial intelligence utilization in greenhouse farming. In *2022 IEEE International Conference on Omni-layer Intelligent Systems (COINS)* (pp. 1-6). IEEE.

Witte, J., Gao, K. y Zöll, A. (2023). Artificial Intelligence: The Future of Sustainable Agriculture? A Research Agenda.

Xue, B., Green, R. y Zhang, M. (2023). Artificial Intelligence in New Zealand: applications and innovation. *Journal of the Royal Society of New Zealand*, 53(1), 1-5.

Zhou, Z., Zahid, U., Majeed, Y., Mustafa, S., Sajjad, M.M., Butt, H.D. y Fu, L. (2023). Advancement in artificial intelligence for on-farm fruit sorting and transportation. *Frontiers in Plant Science*, 14.

INTELIGENCIA ARTIFICIAL EN LA AGRICULTURA PROTEGIDA

INTRODUCCIÓN

La agricultura protegida para el cultivo de vegetales de alto valor y otros cultivos hortícolas como flores y especies medicinales en invernaderos de alta o baja tecnología, permite a los agricultores cultivar especies comerciales en pequeñas superficies en áreas marginales donde la escasez de agua es severa y donde los cultivos tradicionales de grano no son viables.

La agricultura protegida o de ambiente controlado (AP) es un sistema de producción no convencional que es eficiente en recursos, usa menos espacio y produce mayor calidad y rendimiento. La inteligencia artificial emplea el aprendizaje profundo (DL) introducido recientemente en AP para diferentes aplicaciones, incluido el monitoreo de cultivos, la detección de estrés biótico y abiótico, el riego, la predicción del microclima, los controles de eficiencia energética y la predicción del crecimiento de los cultivos (Ojo y Zahid, 2022).

Con la agricultura protegida (AP) en invernaderos, túneles y casas sombra, se cultivan especies agrícolas casi durante cualquier época del año, dentro de un ambiente donde se puede lograr una máxima producción de alta calidad, debido al control que se tiene de la temperatura, humedad, radiación solar, agua de riego, fertilización, tipo de sustrato o suelo, etc. (Figura 18). Mundialmente hay unos 115 países que están usando la AP cubriendo más de un millón de hectáreas con bioespacios como invernaderos, túneles, casas sombra, etc. (Sabir et al., 2013).

La AP de hortalizas y flores ha mostrado su enorme viabilidad y rentabilidad durante las últimas 3 décadas. Con la economía global liberalizada y el advenimiento de nuevas tecnologías, como la IA la AP tiene un gran potencial que antes no se veía en la agricultura (Antignus, 2014) ya que estas tecnologías no son solo para productores de un nivel económico superior, sino que ahora también son factibles para los más pequeños y de menor capacidad económica.

En este contexto México es un país con climas heterogéneos en sus regiones agrícolas, por eso las actividades agrarias tienen niveles muy desiguales de tecnología y productividad, obteniendo ganancias muy desiguales por lo cultivado (Vargas-Canales et al., 2018). Actualmente y en parte como consecuencia de la pandemia provocada por el Covid 19, a nivel global el sector agroalimentario está teniendo una serie de ajustes y cambios tecnológicos, mismos que han incidido en su estructura económica (Perilla et al.,

2019).



Figura 18. La agricultura protegida en invernaderos (A) y semi protegida (B) en casas sombra, ya son de uso generalizado y se emplean globalmente.

AGRICULTURA PROTEGIDA VERTICAL

En los últimos años esta situación se ha intensificado, ya que la globalización ha transformado de manera desigual, la estructura productiva, por eso la AP convencional y la nueva agricultura protegida vertical (APV), tienen el potencial de cambiar la producción de alimentos para satisfacer las demandas de poblaciones y para lograr subsanar en parte los cambios climáticos globales (Shi et al., 2019).

Debido el creciente problema de las sanciones y la naturaleza crónica de las guerras alimentarias de Rusia con países extranjeros cercanos y lejanos, formar un nuevo paradigma organizativo y tecnológico en la agricultura moderna y protegida, es un paso vital para garantizar el bienestar de la toda la sociedad.

Actualmente, en el complejo agroindustrial de la Federación Rusa existe una importante brecha tecnológica para asegurar el crecimiento inteligente de los agronegocios basados en tecnologías y soluciones digitales apoyadas con IA, lo que afecta negativamente la producción, potencial exportador y condición financiera (Aleksandrov et al., 2021).

La APV (Figura 19) ha demostrado ser factible; sin embargo, implica emplear e invertir mucho dinero en las estructuras, así como en energía, tanto de fuentes fósiles, como en fuentes alternas, ya sea eólica, de paneles solares, etc. (McCartney et al., 2018). En el siglo XXI las tierras agrícolas de primera ya son muy escasas y caras, pero el mayor problema agrícola es la creciente carencia de agua para riego.

Con la población mundial en constante crecimiento, ahora es mayor la demanda de más alimentos, pero cada vez hay menos tierra y agua para cultivarlos. Por eso algunos empresarios están empezando a mirar hacia arriba, en el contexto de producir alimentos en

invernaderos verticales que ocupen menos espacio y que estén más cerca de las ciudades o zonas de consumo (Liu et al., 2019).



Figura 19. En la agricultura protegida vertical se controlan todas las variables ambientales que afectan y modifican la fisiología de los cultivos (Tomado de: <https://www.milenio.com/negocios/financial-times/granjas-verticales-opcion-ante-calentamiento-global>).

Una solución a algunas necesidades de más espacio se puede encontrar en los almacenes abandonados de ciudades, nuevos edificios construidos en terrenos dañados por el medio ambiente, e incluso en contenedores de envío usados por los transportes marítimos.

Esta solución, llamada agricultura protegida vertical (APV), implica producir cultivos en condiciones ambientales controladas y temperaturas precisas durante el ciclo de las plantas (Takeshima y Joshi, 2019). En la APV los cultivos en crecimiento se apilan en capas, pudiendo alcanzar varios pisos de altura (Figura 20).

En el trabajo de Howard et al. (2020) se menciona que el crecimiento del sector de los invernaderos comerciales, depende en gran medida del uso óptimo de la energía con múltiples conceptos nuevos introducidos en los últimos años como la IA, tanto para la agricultura vertical como para agricultura horizontal urbana.

Los gemelos digitales (digital twins) usados mucho en la IA permiten utilizar el Internet de las cosas (IoT) y big data para simular las estrategias de operación alternativas

sin comprometer la operación actual de los equipos en invernaderos. Los gemelos digitales pueden estimar los estados futuros del invernadero mediante el uso de entradas de datos pasados y en tiempo real mediante bases de datos, biosensores y nanosensores.

A principios del año 2015 en los Estados Unidos, sólo había unas pocas instalaciones o granjas con APV en funcionamiento. Pero el interés en esto hace que la nueva tecnología agrícola está creciendo rápidamente. Las granjas verticales vienen en diferentes formas y tamaños, desde sistemas sencillos de dos niveles o hasta grandes almacenes de varios pisos de altura conteniendo muchas plantas. De esa manera se tiene un elevado índice de área foliar por metro cuadrado.



Figura 20. Con la agricultura vertical es posible la producción de una gran cantidad de diversos alimentos en un pequeño espacio, ahorrando mucha agua y nutrientes (Tomado de: <https://pixabay.com/es/photos/granja-vertical-pared-verde-bok-choy-916337/>).

Bogstie et al. (2021) indican que la APV es sostenible porque utiliza mucho menos tierra y agua que las granjas a campo abierto, y no requiere pesticidas ni herbicidas. La agricultura vertical es un sistema innovador que puede usar la IA para controlar factores

como la luz, temperatura, concentración de CO_2 y los macro y micro nutrientes para producir mayores rendimientos y productos frescos y nutritivos.

Todas las granjas verticales utilizan uno de tres sistemas de producción sin suelo, pero utilizando mezclas de sustratos como: perlita, zeolita, lana de roca, turba o peat moss, etc., para proporcionar el agua y los nutrientes requeridos por las plantas. Los sistemas de producción sin suelo son: hidroponía, aeroponía o acuaponía (Birkby, 2016). La siguiente información describe esos tres sistemas de cultivo.

1. **Hidroponía.** Este sistema de producción es el predominante en agricultura protegida y en granjas verticales. La hidroponía implica el cultivo de plantas sin tierra, utilizando sustratos minerales u orgánicos y aplicando soluciones nutritivas que proveen todos los minerales requeridos por los cultivos (Figura 21). Las raíces de las plantas reciben la solución nutritiva, la cual que se monitorea y recircula con frecuencia, garantizando así que la composición química sea correcta y balanceada.



Figura 21. Sistema hidropónico para la producción de hortalizas, controlando con precisión el agua de riego y los nutrientes en cada etapa del crecimiento (Tomado de: <https://www.istockphoto.com/es/foto/finca-vertical-hidropon%C3%ADa-en-edificio-con-agricultura-de-alta-tecnolog%C3%ADa-invernadero-gm1211174924-351141962>).

2. **Aeroponía.** La Administración Nacional de Aeronáutica y del Espacio (NASA) de Estados Unidos, fue la institución responsable de desarrollar esta innovadora técnica de cultivo agrícola. En la década de 1990, la NASA interesada en

encontrar formas eficientes de producir plantas en el espacio, acuñó el término “aeroponia”, definido como “el crecimiento de plantas en un ambiente protegido sin suelo y con muy poca agua” (Lakhier et al., 2018).

Un sistema aeropónico (Figura 22) es el método de cultivo de plantas más eficiente para la tecnología APV, ya que utiliza hasta 90% menos de agua, incluso que los sistemas hidropónicos más eficientes. Plantas cultivadas en estos sistemas aeropónicos ha demostrado que absorben más minerales y nutrientes, lo que hace que las plantas sean saludables y nutritivas.



Figura 22. Los sistemas aeropónicos requieren menos agua que los hidropónicos para producir cultivos, pero su uso no se ha generalizado aún (Tomado de: <https://www.portalfruticola.com/noticias/2016/12/13/guia-para-construir-un-sistema-de-cultivo-aeroponico/>).

3. **Acuaponia.** Un sistema acuapónico se sustenta en el sistema hidropónico, pero va un paso más allá, ya que combina la producción simultánea de plantas y peces en un mismo ecosistema o invernadero. Los peces se cultivan en los estanques inferiores, produciéndose ahí desechos ricos en nutrientes, los que se utilizan como alimento para las plantas sembradas en los estratos superiores de la granja vertical. Las plantas, a su vez, filtran y depuran las aguas residuales, mismas que nuevamente se reciclan para los peces del estanque (Palm et al., 2018).

Aunque la acuaponia (Figura 23) se utiliza en menor escala en sistemas agrícolas verticales, la mayoría de estos sistemas verticales se centran en producir solo algunos cultivos de hortalizas de rápido crecimiento, sin incluir un componente de acuaponia. Esto simplifica las cuestiones económicas y de producción, al tiempo que maximiza la eficiencia productiva. Sin embargo, los nuevos sistemas acuapónicos pueden ayudar a que este sistema de ciclo cerrado sea más popular.




Figura 23. Con los sistemas de acuaponia se obtienen alimentos vegetales como hortalizas, así como la producción de proteína animal, mediante la cría de peces en estanques donde coexisten en diferentes estratos las plantas y los animales (Tomado de: <http://edomexinforma.com.mx/sedagro-supervisa-produccion-simultanea-de-peces-y-plantas-alimenticias/>).

La agricultura vertical que usa *aeroPonia* es una técnica sin suelo y que mezcla la aplicación de un aerosol de nutrientes a las raíces, lo que puede conducir a una mayor productividad de las plantas en comparación con el cultivo hidropónico. Se cree que la *aeroponia* resuelve una variedad de restricciones fisiológicas de las plantas que crecen dentro de los sistemas hidropónicos (Eldridge et al., 2020).

Esta técnica también proporciona una amplia gama de información que podría ser esencial para los investigadores y proporciona una mayor comprensión de cómo los parámetros clave de la *aeroponia* se correlacionan con el crecimiento de las plantas en el sistema. También ofrece un control total del sistema, no por la atención manual constante del operador, sino en gran medida por sensores inalámbricos. Además, la adopción de técnicas inteligentes en el sistema *aeropónico* podría reducir el concepto de la utilidad del sistema debido al complicado proceso de seguimiento y control manual (Lakhier et al., 2018).

USOS DE LA INTELIGENCIA ARTIFICIAL EN BIOESPACIOS Y CAMPO ABIERTO

El control de las condiciones ambientales y el seguimiento del estado fenológico y fitosanitario de las plantas en los bioespacios o invernaderos, son fundamentales para tomar decisiones de manejo adecuadas con el fin de promover la producción de cultivos.

El objetivo principal del estudio de Narimani et al. (2021) fue desarrollar y evaluar un invernadero aeropónico inteligente a escala experimental donde el estado de las plantas de geranio y las condiciones ambientales se monitorearon continuamente a través de la integración del IoT y la inteligencia artificial.

La agricultura tiene un gran impacto en la economía mundial; sin embargo, los cultivos dependen del clima. Esto afecta especialmente a las regiones del norte del mundo, en particular al Ártico. Con baja autosuficiencia agrícola, esta región tiene que depender de las importaciones de alimentos.

Esto crea un déficit, lo que conduce a precios muy altos de verduras y frutas, así como una nutrición desequilibrada de los habitantes del Ártico que carecen de alimentos naturales y frescos por carecer de campos de cultivo e invernaderos (Sidorova et al., 2022). Debido a eso el uso de la APV apoyada con la IA representa una opción factible para producir alimentos sanos de productos hortícolas, así como medicinales, granos y de ornato.

La agricultura vertical es un nuevo sistema agrícola que tiene como objetivo utilizar el acceso limitado a la tierra, especialmente en las grandes ciudades. Esta opción es la respuesta que Siregar et al. (2022) consideran que es la mejor para enfrentar los desafíos que plantea la escasez de tierra y agua, incluida la agricultura urbana. La IA con aprendizaje automático, aprendizaje profundo e IoT para respaldar la AP, se ha utilizado de manera óptima, especialmente en su aplicación a la moderna agricultura vertical que produce hortalizas y granos.

Recientemente Zhu y Marcelis (2023) consignan que la empresa Infarm ha anunciado un gran avance en la APV al producir granos (trigo) con éxito, logrando un impresionante rendimiento de 11.7 kg por m² o sea 117 ton ha⁻¹ de superficie de suelo a cielo abierto. Esto abre las posibilidades de un cambio paradigmático respecto de la producción de granos básicos en condiciones de APV, ya que según la ONU la superficie de tierra cultivable del mundo se ha reducido en 33% desde 1961, y fue de 1.38 mil millones ha en 2019.

Estudios recientes publicados por Petropoulou et al. (2023), indican que la demanda de alimentos aumentará entre 35 y 56% durante el período 2010-2050 debido al aumento de la población, el desarrollo económico y la urbanización. Debido a eso, los sistemas de invernadero horizontal y vertical permiten la intensificación sostenible de la producción de alimentos con una alta producción por área cultivada. Los avances en la producción de alimentos frescos con el uso eficiente de los recursos que combinan la experiencia en la APV y la IA se realizan adecuadamente con los invernaderos horizontales o verticales que emplean IA.

La APV puede producir alimentos de una manera resiliente al clima, potencialmente sin emisiones de pesticidas ni fertilizantes, y con un menor uso de tierra y agua que la agricultura convencional. Los sistemas agrícolas verticales APV pueden satisfacer las demandas diarias de los consumidores de productos frescos y nutritivos, formando parte de sistemas alimentarios en y alrededor de áreas densamente pobladas (Van Delden et al., 2021).

Los sistemas de AP producen una gama limitada de cultivos que incluyen frutas, verduras y hierbas, pero la implementación exitosa de la APV como parte de la agricultura convencional requerirá mejoras en la rentabilidad, la eficiencia energética, las políticas públicas y la aceptación del consumidor.

Lutz y Coradi (2022) en su artículo revelan que los estudios actuales en AP y especialmente en agricultura vertical protegida, están abordando el uso de sensores en granos almacenados, así como el IoT y tecnologías de ML en poscosecha, para identificar recursos y nuevas posibilidades de desarrollo tecnológico que ayuden en el seguimiento de la calidad de los granos almacenados (Figura 24). Por lo tanto, su calidad se puede predecir mediante el control del contenido de humedad ambiental y del grano, así como la concentración de CO₂ en el aire intergranular.

La APV está en camino de convertirse en una adición a las prácticas agrícolas convencionales, mejorando la producción sostenible de alimentos para la creciente población mundial bajo un estrés climático cada vez mayor. Van Gerrewey et al. (2022) señalan, que el desarrollo inicial de los sistemas de APV se centró en el avance tecnológico a través de la innovación en el diseño, la automatización del cultivo hidropónico y los sistemas avanzados de iluminación LED, los estudios más recientes se centran en la resiliencia y la circularidad de la APV.

La vida cotidiana de las personas está cambiando debido al aumento de los efectos del cambio climático. En los tiempos del Covid-19, por las precauciones como quedarse en casa, la gente trató de obedecer esas precauciones. Este tipo de protecciones redujo las emisiones de CO₂ en 17%, consiguiendo que el mundo volviera a los valores de emisiones de gases de 2006 (Naskali et al., 2022). Debido a eso el aire se volvió más respirable y la naturaleza comenzó a repararse sin el contacto de la gente. A medida que la población crece, la alimentación de esta población se ha convertido en un problema grande, ya que la gente comenzó a destruir áreas forestales porque se necesitaba más agricultura para más nutrición.




Figura 24. En condiciones de agricultura protegida y en campo abierto se pueden optimizar operaciones de riego, fertilización, control de plagas y enfermedades mediante el uso de la internet de las cosas (IoT) y aprendizaje profundo usando diversos algoritmos y software (Tomado de: Lutz y Coradi, 2022).

El uso inteligente de la tecnología de invernaderos se ha demostrado en prototipos de sistemas automáticos de control climático (software y hardware) basados en modelos matemáticos de la tecnología y clima de invernaderos, así como de la fisiología de cultivos (Howard et al., 2021). Además, los avances recientes en IA con modelos dinámicos para la utilización de iluminación artificial suplementaria basados en pronósticos meteorológicos y precios de la energía, que equilibran el uso de electricidad con el estado de la red eléctrica, se suman a la complejidad.

La producción de alimentos en condiciones de AP ha evolucionado desde el invernadero tradicional hasta el invernadero vertical agroindustrial que actualmente se caracteriza por su modernidad porque usa IA y su alto nivel de automatización (calefacción, sistema de nebulización, aire acondicionado, control, regulación y mando, ordenador de supervisión, etc.).

Actualmente, el control climático en AP mediante softwares computacionales ofrece múltiples servicios y permite solucionar problemas de regulación, control y mando. Hadidi

et al. (2021) señalan que la principal motivación para elegir la IA es mejorar el rendimiento y el manejo del clima interno, para avanzar hacia una estrategia de control-mando para conseguir una estructura de cálculo homogénea mediante un algoritmo o modelo matemático, utilizable por un lado para la síntesis del controlador y por otro lado por la simulación de las actuaciones del sistema.

En el trabajo de Popkova (2022) se señala que los invernaderos verticales basadas en hidroponía, aprendizaje profundo e IA son una innovación de la agricultura inteligente asequible y un camino hacia la Agricultura 4.0, cuyos beneficios incluyen: (1) la posibilidad de establecer e implementar agricultura altamente eficiente en ciudades y campo abierto, independientemente del clima (autonomía); (2) propiedades nutricionales de los alimentos; (3) aumento de la productividad y (4) continuidad del ciclo agrícola durante todo el año en el mismo lugar.

USOS DE LA INTELIGENCIA ARTIFICIAL EN LA PRODUCCIÓN DE ALIMENTOS

En los últimos años, el mundo de la agricultura ha visto un cambio dramático en la forma en que se producen los alimentos. Desde la aplicación de técnicas de agricultura de precisión hasta la introducción de la automatización. Uno de los avances más prometedores es la aplicación de la IA, la cual tiene el potencial de revolucionar la forma en que se cultivan, cosechan y procesan los alimentos, brindando muchos beneficios para los agricultores, consumidores y el ambiente.

Además, la IA puede ayudar a reducir el desperdicio de alimentos, mejorar la seguridad alimentaria y crear prácticas de cultivo sustentables. Las principales ventajas de la IA en la AP vertical u horizontal son las siguientes:

1. **Ayuda a optimizar las operaciones.** La IA se puede utilizar para optimizar las operaciones agrícolas de varias maneras. Los conocimientos basados en IA pueden ayudar a los agricultores a monitorear sus cultivos e identificar posibles problemas antes de que surjan. Esto se puede hacer mediante el uso de sensores, cámaras y análisis de datos.
2. **IA y prácticas de cultivo sustentable.** La IA también se puede utilizar para promover prácticas de cultivo sustentables, ya que ayuda a los agricultores a comprender mejor el impacto de sus operaciones en el ambiente, permitiéndoles tomar decisiones informadas para reducir su huella ambiental. Por ejemplo, la IA puede ayudar a los agricultores a identificar la forma más eficiente de usar sus recursos, como el agua y los fertilizantes, así como a identificar áreas de tierra que se pueden usar para prácticas agrícolas sustentables. La IA se puede usar para monitorear la calidad del aire y del suelo para garantizar que los contaminantes no dañen los cultivos ni a los humanos.
3. **Mejora la seguridad alimentaria.** El uso de la IA en la agricultura también

puede ayudar a mejorar la seguridad alimentaria. Los conocimientos basados en IA se pueden utilizar para detectar problemas potenciales desde el principio, lo que permite a los agricultores tomar medidas antes de que los cultivos se infecten. Esto puede reducir la cantidad de desperdicio de alimentos y garantizar que los cultivos sean seguros para el consumo. Además, la IA se puede utilizar para detectar e identificar plagas, enfermedades y otros contaminantes, lo que permite a los agricultores tomar medidas preventivas y correctivas.

4. **Reduce el desperdicio de alimentos.** La IA también se puede utilizar para reducir el desperdicio de alimentos. Los conocimientos basados en IA pueden auxiliar a los agricultores a identificar áreas de la granja donde se desperdician alimentos, lo que les permite tomar medidas correctivas. Esto puede reducir la cantidad de alimentos que se desperdician y ayudar a los agricultores a maximizar sus rendimientos. Además, la IA se puede usar para controlar la calidad de los alimentos, lo que permite a los agricultores detectar y descartar cualquier alimento que no sea apto para el consumo.
5. **Automatización de la agricultura.** La IA también se puede utilizar para automatizar ciertos aspectos del proceso agrícola. La automatización impulsada por IA puede ayudar a los agricultores a administrar sus operaciones de manera más eficiente, reduciendo los costos laborales y aumentando la eficiencia. Esto se puede hacer usando robots, drones y otros sistemas automatizados. Los robots se pueden usar para monitorear cultivos e identificar posibles problemas, mientras que los drones se pueden usar para entregar fertilizantes, pesticidas y agua a los cultivos.
6. **Mejora las experiencias de los clientes.** La IA también se puede utilizar para mejorar las experiencias de los clientes. Los conocimientos basados en IA pueden ayudar a los agricultores a comprender mejor las necesidades y preferencias de sus clientes, lo que les permite adaptar sus productos y servicios en consecuencia. Esto puede ayudar a los agricultores a aumentar la satisfacción de los clientes, así como sus ganancias. Además, la IA se puede utilizar para desarrollar recomendaciones personalizadas para los clientes, permitiéndoles encontrar los productos y servicios que mejor se adaptan a sus necesidades.
7. **Información basada en datos de IA.** La IA también puede proporcionar información basada en datos que puede ayudar a los agricultores a tomar decisiones más informadas. Los conocimientos basados en IA pueden ayudar a los agricultores a identificar áreas de sus operaciones que podrían mejorarse, permitiéndoles optimizar sus operaciones y aumentar los rendimientos. Además, la IA se puede utilizar para analizar las tendencias del mercado y el comportamiento de los clientes, lo que permite a los agricultores comprender mejor las necesidades y preferencias de sus clientes.
8. **Mejora los rendimientos y reduce los costos.** La IA en la agricultura también puede ayudar a mejorar los rendimientos y reducir costos. La IA pueden ayudar a los agricultores a identificar áreas de sus operaciones que se pueden mejorar, lo que les permite reducir sus costos y aumentar sus rendimientos. La IA se puede usar para optimizar el uso del agua y los fertilizantes, así como identificar áreas de tierra que se pueden utilizar para prácticas agrícolas más eficientes.

También puede ayudar a automatizar ciertos aspectos como la fumigación y la cosecha de cultivos, lo que permite a los agricultores reducir sus costos de mano de obra.

9. **La IA y el futuro de la agricultura.** El potencial de la IA en la agricultura es inmenso y sus aplicaciones apenas comienzan a explorarse. A medida que la tecnología continúa evolucionando, las oportunidades para la IA en la agricultura aumentarán. Los conocimientos basados en IA pueden ayudar a los agricultores a optimizar sus operaciones, reducir costos y aumentar los rendimientos. Además, la IA se puede utilizar para promover prácticas de cultivo sustentables, reducir el desperdicio de alimentos y mejorar la seguridad alimentaria.

CONCLUSIONES

La agricultura protegida vertical en áreas urbanas es un fenómeno moderno. El interés en este enfoque es creciente, así que el número de granjas verticales en el mundo aumentará cada año. Existen variaciones en la forma y funcionamiento de estas granjas que se están probando en todo el mundo, así como nuevas innovaciones tecnológicas, mismas que en el futuro cercano aumentarán la eficiencia y los márgenes de ganancias de los sistemas verticales de producción.

A corto plazo, la mayoría de las granjas verticales se centrarán en cultivos de alta rentabilidad como verduras para ensalada, las cuales serán entregadas a restaurantes y centros de población cercanos. Las innovadoras granjas verticales actualmente en construcción, o ya en producción, están siendo observadas muy de cerca por los planificadores urbanos, la comunidad y los gobiernos que apoyan la agricultura ecológica y sostenible.

A medida que la tecnología continúa evolucionando, el potencial de la IA en la agricultura es inmenso. Al desbloquear el poder de la IA, los agricultores pueden obtener acceso a una variedad de información basada en datos, lo que les permite tomar decisiones más informadas y optimizar sus operaciones.

Esto les permitirá aumentar los rendimientos, reducir los costos y administrar mejor sus recursos. Además, la IA puede ayudar a reducir el desperdicio de alimentos, mejorar la seguridad alimentaria y crear prácticas de cultivo sostenibles. A medida que la tecnología continúa evolucionando, el potencial de la IA en la agricultura es inmenso.

LITERATURA CITADA

Aleksandrov, I., Daroshka, V., Isakov, A., Chekhovskikh, I. y Borisova, E. (2021). AgroTech investment and AgroSmart economy in Russia. In E3S Web of Conferences (Vol. 284, p. 07021). EDP Sciences.

Antignus, Y. (2014). Management of air-borne viruses by optical barriers. In: protected agriculture and open-field crops. *Advances in virus research*, 90, 1-33.

Birkby, J. (2016). Vertical farming. *ATTRA Sustainable Agriculture*, 1-12.

Bogstie, E. (2021). Vertical Farming: A viable strategy for sustainable agriculture (Doctoral dissertation, Thompson Rivers University).

Eldridge, B.M., Manzoni, L.R., Graham, C.A., Rodgers, B., Farmer, J. R. y Dodd, A.N. (2020). Getting to the roots of aeroponic indoor farming. *New Phytologist*, 228(4), 1183-1192.

Hadidi, A., Saba, D. y Sahli, Y. (2021). The role of artificial neuron networks in intelligent agriculture (case study: greenhouse). *Artificial Intelligence for Sustainable Development: Theory, Practice and Future Applications*, 45-67.

Howard, D.A., Ma, Z., Aaslyng, J.M. y Jørgensen, B.N. (2020, October). Data architecture for digital twin of commercial greenhouse production. In 2020 RIVF International Conference on Computing and Communication Technologies (RIVF) (pp. 1-7). IEEE.

Lakhiar, I.A., Jianmin, G., Syed, T.N., Chandio, F.A., Buttar, N.A. y Qureshi, W.A. (2018). Monitoring and control systems in agriculture using intelligent sensor techniques: A review of the aeroponic system. *Journal of Sensors*, 2018, 1-18.

Lakhiar, I.A., Gao, J., Syed, T.N., Chandio, F.A. y Buttar, N.A. (2018). Modern plant cultivation technologies in agriculture under controlled environment: A review on aeroponics. *Journal of plant interactions*, 13(1), 338-352.

Liu, N., Jiang, X., Cheng, J., Li, H., Li, W., Xue, K. y Xiong, Z. (2018). Current situation of foreign organic greenhouse horticulture and its inspiration for sustainable development of Chinese protected agriculture. *Transactions of Chinese Society of Agricultural Engineering*, 34(15), 1-9.

Lutz, E. y Coradi, P.C. (2022). Applications of new technologies for monitoring and predicting grains quality stored: Sensors, internet of things, and artificial intelligence. *Measurement*, 188, 110609.

McCartney, L. y Lefsrud, M. (2018). Protected agriculture in extreme environments: a review of controlled environment agriculture in tropical, arid, polar, and urban locations. *Applied Engineering in Agriculture*, 34(2), 455-473.

Narimani, M., Hajjahmad, A., Moghimi, A., Alimardani, R., Rafiee, S. y Mirzabe, A.H. (2021). Developing an aeroponic smart experimental greenhouse for controlling irrigation and plant disease detection using deep learning and IoT. In 2021 ASABE Annual International Virtual Meeting (p. 1). American Society of Agricultural and Biological Engineers.

Naskali, A.T., Pinarer, O. y Tolga, A.C. (2022). Vertical farming: under climate change effect. *Environment and climate-smart food production*, 259-284.

- Ojo, M.O. y Zahid, A. (2022). Deep learning in controlled environment agriculture: A Review of Recent Advancements, Challenges and Prospects. *Sensors*, 22(20), 7965.
- Palm, H.W., Knaus, U., Appelbaum, S., Goddek, S., Strauch, S.M., Vermeulen, T. y Kotzen, B. (2018). Towards commercial aquaponics: a review of systems, designs, scales and nomenclature. *Aquaculture International*, 26(3), 813-842.
- Perilla, G.A. y Mas, J.F. (2019). High-resolution mapping of protected agriculture in Mexico, through remote sensing data geo processing. *European Journal of Remote Sensing*, 52(1), 532-541.
- Petropoulou, A.S., van Marrewijk, B., de Zwart, F., Elings, A., Bijlaard, M., van Daalen, T. y Hemming, S. (2023). Lettuce production in intelligent greenhouses—3D imaging and computer vision for plant spacing decisions. *Sensors*, 23(6), 2929.
- Popkova, E.G. (2022). Vertical farms based on hydroponics, deep learning, and AI as smart innovation in agriculture. In *Smart Innovation in Agriculture* (pp. 257-262). Singapore: Springer Nature Singapore.
- Shi, X., An, X., Zhao, Q., Liu, H., Xia, L., Sun, X. y Guo, Y. (2019). State-of-the-art internet of things in protected agriculture. *Sensors*, 19(8), 1833.
- Sabir, N., y Singh, B. (2013). Protected cultivation of vegetables in global arena: A review. *Indian Journal of Agricultural Sciences*, 83(2), 123-35.
- Sidorova, N.G., Druzhinina, A.R., Nedostup, M.A. y Osipov, V.S. (2022). Vertical greenhouses in the arctic. In *The Handbook of the Arctic: A Broad and Comprehensive Overview* (pp. 1-11). Singapore: Springer Nature.
- Siregar, R.R.A., Seminar, K.B., Wahjuni, S. y Santosa, E. (2022). Vertical farming perspectives in support of precision agriculture using artificial intelligence: A Review. *Computers*, 11(9), 135.
- Takeshima, H. y Joshi, P.K. (2019). Protected agriculture, precision agriculture, and vertical farming: Brief reviews of issues in the literature focusing on the developing region in Asia (Vol. 1814). *Intl Food Policy Res. Inst.*
- Van Delden, S.H., SharathKumar, M., Butturini, M., Graamans, L.J.A., Heuvelink, E., Kacira, M. y Marcelis, L.F.M. (2021). Current status and future challenges in implementing and upscaling vertical farming systems. *Nature Food*, 2(12), 944-956.
- Van Gerrewey, T., Boon, N. y Geelen, D. (2022). Vertical farming: The only way is up?. *Agronomy*, 12(1), 2.
- Vargas-Canales, J.M., Palacios-Rangel, M.I., Aguilar-Ávila, J., Ocampo-Ledesma, J.G., Kreimer, P. y Ortiz-Martínez, G. (2018). Technological innovation in a case of protected agriculture in Mexico. *Revista de Geografía Agrícola*, 61(2), 9-38.
- Zhu, X.G. y Marcelis, L. (2023). Vertical farming for crop production. *Modern Agriculture*.

INTELIGENCIA ARTIFICIAL CONTRA PLAGAS Y ENFERMEDADES

INTRODUCCIÓN

El reporte de Amrillojonovich (2023) señala que el sector agrícola es la columna vertebral de cualquier economía en desarrollo, y para obtener el máximo rendimiento de los cultivos, los agricultores deben contar con las mejores tecnologías y metodologías. La inteligencia artificial (IA) está teniendo amplias aplicaciones en diversos sectores, incluida la agricultura.

Debido a su capacidad para percibir los problemas, desarrollar las razones adecuadas para ello y establecer soluciones óptimas a los mismos, la IA puede ser de gran ayuda para la detección y el manejo de plagas y enfermedades que afectan a los cultivos, además, puede ser empleada para diversos beneficios de la agricultura (Figura 25).



Figura 25. Esquema que ilustra los beneficios que puede aportar el uso de la inteligencia artificial en la agricultura moderna de precisión, incluyendo mejorar el uso del agua y los agroquímicos para tener un ecosistema sustentable.

La identificación y clasificación automática de insectos y enfermedades ha atraído a los investigadores durante muchos años; apoyados con la IA ya hay varios algoritmos para solucionar los problemas de identificación manual de insectos y plagas. Las técnicas de procesamiento de imágenes y las redes neuronales (CNN) pueden superar los desafíos de la identificación y clasificación manual de insectos.

El trabajo de Gupta et al. (2023) se centró en optimizar y evaluar redes CNN para identificar insectos. Señalan que DenseNet 201 funcionó bien y con la mayor precisión de prueba. Con respecto al tiempo de capacitación, AlexNet funcionó bien, pero comentan que ShuffleNet, SqueezeNet y MobileNet son mejores opciones técnicas de IA para

arquitecturas pequeñas.

INTELIGENCIA ARTIFICIAL EN LA DETECCIÓN Y CLASIFICACIÓN DE PLAGAS

El programa de manejo integrado de plagas (MIP) enfatiza el uso de trampas adhesivas y recursos naturales para controlar las poblaciones de plagas, ya que es una táctica de manejo ecológica que depende de variables biológicas y ambientales. Hanif et al. (2023) mencionan que los expertos agrícolas son de gran importancia en el MIP, pero este es un proceso que requiere mucho tiempo y mano de obra para monitorear manualmente la población de plagas.

Por eso, ahora es crucial desarrollar sistemas de IA (Figura 26) que consideren todos los factores, incluidas las variables bióticas y abióticas para predecir la ocurrencia de plagas y poder así realizar las aplicaciones de pesticidas oportunamente en el campo.



Figura 26. La inteligencia artificial ha tenido grandes avances en la agricultura, debido a que un sistema que considera todos los factores, incluidas las variables bióticas y abióticas, puede predecir la ocurrencia de plagas y enfermedades, permitiendo que el agricultor realice las aplicaciones de pesticidas oportunamente.

La detección y clasificación exitosas de insectos a partir de imágenes de trampas adhesivas utilizando YOLOv5 ha sido evaluada por Kalfas et al. (2023), quienes encontraron que: Un enfoque de IA centrado en los datos para el monitoreo de insectos es clave en el desarrollo de modelos robustos de detección de insectos; el mosaico de imágenes de placas adhesivas de alta resolución es importante para detectar insectos pequeños; la clasificación de insectos con niveles taxonómicos compartidos es representativa de la situación real en el campo. Los autores concluyen señalando que la detección y clasificación exitosas de

insectos es factible realizarla a partir de imágenes utilizando el software YOLOv5.

Detectar, clasificar y monitorear plagas de insectos en un almacén de granos o alimentos en tiempo real es vital para tomar decisiones para el control de insectos; por eso y mediante un sistema básico, Mendoza et al. (2023) desarrollaron un sistema de detección de insectos consistente en una cámara de enfoque manual, un Jetson Nano, una computadora de bajo costo y un modelo de aprendizaje profundo entrenado.

El modelo fue validado a través de una transmisión visual en vivo con tres situaciones de iluminación diferentes: luz LED blanca, luz LED amarilla y sin condiciones de iluminación, los resultados de la detección se muestran en un monitor y revelan que es una solución de IA automatizada, eficaz y asequible para la detección de insectos, por lo que puede ayudar a reducir los costos de control de plagas y ahorrar tiempo y energía a los productores.

Debido a la destrucción y los incendios forestales, algunas especies de insectos podrían extinguirse sin ser detectadas. Identificar nuevos insectos y tener conocimientos sobre su biodiversidad contribuirá a los estudios que se realicen en entomología, agricultura, industria farmacéutica, medicina, robótica y otras ramas. En este sentido Ozdemir y Kunduraci (2022), produjeron un software basado en dispositivos móviles con un modelo de aprendizaje profundo para clasificar y detectar insectos, mediante análisis comparativos de aprendizaje profundo SSD MobileNET, YoloV4 y Faster R-CNN InceptionV3.

Los autores concluyen que Faster R-CNN InceptionV3 funciona mejor en la clasificación y detección de insectos a nivel de orden. Como resultado, creen que esta investigación será beneficiosa para entomólogos, naturalistas y otros investigadores al usar un sistema móvil como un teléfono inteligente (Figura 27).



Figura 27. Mediante el empleo de software basado en dispositivos móviles como un teléfono y con un modelo de aprendizaje profundo, basado en inteligencia artificial es posible clasificar y detectar insectos en las etapas críticas para su prevención y control. (Tomado de: <https://d3.harvard.edu/platform-digit/submission/john-deere-using-ai-to-reimagine-farming/>).

La clasificación de plagas es esencial para una economía agrícola fuerte y sustentable y para la seguridad alimentaria. Sin embargo, la clasificación de plagas es un proceso lento que requiere conocimiento y depende de la experiencia del personal técnico. Por lo tanto, la automatización del proceso de clasificación puede reducir costos, mejorar la precisión y facilitar el análisis de datos con imágenes hiperespectrales.

En el reporte de Ayan (2023) se señala que las redes neuronales convolucionales (CNN) y los métodos de ajuste fino del aprendizaje por transferencia, han ganado popularidad para resolver muchos problemas de visión por computadora en la agricultura. Los modelos CNN optimizados lograron precisiones de última generación en conjuntos de datos y de acuerdo con los resultados, los algoritmos clasifican efectivamente varias plagas de cultivos y pueden usarse en la agricultura para ayudar a salvar o reducir el daño a los cultivos.

La industria citrícola sudafricana se enfrenta a la devastadora enfermedad de los cítricos llamada Huanglongbing (HLB). *Diasphorina citri* es el vector principal de HLB, pero también puede ser transmitida por una plaga autóctona de Sudáfrica, el triozid cítrico africano (ACT), *Trioza erytreae*. En una investigación de da Cunha et al. (2022) están utilizando trampas adhesivas amarillas en huertos de Sudáfrica para el monitoreo continuo de ACT.

La identificación de ACT en las trampas requiere personal calificado, lo que puede resultar problemático cuando la captura se realiza a gran escala. Por eso, para hacer más preciso y eficiente el seguimiento del vector HLB, estos autores desarrollaron un sistema de detección automática de plagas utilizando IA, mediante tres modelos de aprendizaje automático usando diferentes arquitecturas de redes neuronales y desarrollando el algoritmo Faster R-CNN para detectar y distinguir el ACT de otras especies en las trampas.

INTELIGENCIA ARTIFICIAL EN PREVENCIÓN Y CONTROL DE PLAGAS Y ENFERMEDADES

La automatización mediante la IA en el sector agrícola basada en la visión artificial (VA) es esencial para satisfacer la demanda de alimentos de una población en rápido crecimiento. Además, puede mejorar la productividad y calidad al reducir los errores y agregar flexibilidad en la prevención y control de plagas y enfermedades en los cultivos agrícolas.

Shin et al. (2023) indican que la tecnología de VA se ha utilizado para desarrollar sistemas de producción de cultivos mediante la detección de enfermedades de manera más eficiente. La VA proporciona una descripción de las aplicaciones para la detección de

estreses y enfermedades en cultivos, hojas, frutas y verduras con las nuevas tendencias tecnológicas de IA, así como las expectativas futuras en la agricultura de precisión. Entre las plagas más comunes y graves de las plantas de tomate, se encuentran las moscas minadoras (*Liriomyza sativae*). Es una de las principales plagas del tomate en todo el mundo.

Por lo tanto, el objetivo del trabajo de Martins Crispi et al. (2023) fue desarrollar un modelo de aprendizaje automático para la detección y estimación automática de la severidad de los síntomas de los ataques de moscas minadoras en hojas de tomate. Se compararon tres softwares y cuatro columnas vertebrales diferentes para una tarea de segmentación semántica multiclase usando exactitud, precisión, recuperación e intersección sobre métricas de unión. Una comparación de los resultados de la segmentación reveló que el modelo U-Net con la red troncal Inceptionv3 logró los mejores resultados.

La utilización de vehículos aéreos no tripulados (drones) en la agricultura de precisión ha ganado últimamente mucha atención por parte de la comunidad científica. El artículo de Refaai et al. (2022) hace contribuciones significativas al analizar los protocolos de comunicación y aplicarlos al desafío de comandar una flota de drones para proteger en el campo a los cultivos de las infestaciones de insectos y enfermedades (Figura 28). El estudio mediante la asistencia de drones apoya mucho la agricultura de precisión.



Figura 28. La inteligencia artificial con el apoyo de drones y softwares especializados de imágenes hiperspectrales, pueden detectar la presencia de plagas y patógenos en el campo, donde los cultivos pueden recibir aplicaciones terrestres o aéreas de agroquímicos para realizar el fitocontrol. (Tomado de: <https://www.businessinsider.com/farmers-artificial-intelligence-in-agriculture-catch-disease-pests?r=MX&IR=T>).

En esa investigación, los autores miden la efectividad de nueve poderosos modelos de redes neuronales profundas para la detección de enfermedades de las plantas utilizando diversas metodologías. Estas redes neuronales profundas se adaptan a la situación inmediata del cultivo utilizando aprendizaje de transferencia y enfoques de extracción profunda de características fenotípicas.

Por otro lado, el cultivo de yute de la familia *Malvaceae* produce una buena fibra de usos múltiples, pero sufre muchas pérdidas físicas y económicas debido a varias infestaciones de plagas de insectos, como el ácaro amarillo (*Polyphagotarsonemus latus* Banks) y el yute semilooper (*Anomis sabulifera* Guen).

Las parcelas construidas por Sarkar et al. (2023) revelan que se han ajustado y validado diferentes modelos de pronóstico de la presencia de estos insectos con programas como: ARIMA, ARIMAX, SARIMA, SARIMAX y SVR usando valores RMSE. En el caso de yute semilooper, se encontró que el modelo SARIMAX es el que mejor se ajusta, seguido de SVR y SARIMA. De manera similar, para Yellow Mite, el modelo ARIMAX produce el menor valor de RMSE, seguido de SVR.

La agricultura fotovoltaica (AF) es un nuevo sistema de manejo agropecuario que combina la industria con la agricultura moderna que puede reducir de manera efectiva la competencia por el uso limitado de los recursos de la tierra entre la producción de energía eléctrica y la producción agropecuaria (Figura 29).



Figura 29. La agricultura fotovoltaica es un modelo emergente de agricultura y ganadería de precisión, la cual involucra la inteligencia artificial y el uso de satélites de detección remota y aplicaciones de pesticidas mediante drones o vehículos no tripulados. (Tomado de: <https://ec.linkedin.com/in/estefania-baldeon-15684747>).

Sin embargo, la AF se ha enfrentado al desafío de administrar las medidas de

protección de las plantas cultivadas, ya que es difícil monitorear las plantas cultivadas bajo los paneles fotovoltaicos mediante satélites de detección remota, así como hacer las aplicaciones de pesticidas mediante drones.

Para superar este desafío, Huang et al. (2023) mencionan que las lámparas solares insecticidas (SIL) se pueden usar para la fitoprotección en la AF. Sin embargo, para usar los SIL de manera efectiva en la AF, es importante identificar una ubicación de campo adecuada para mantener fuertes señales de comunicación inalámbrica. En el trabajo de esos autores, se diseñaron dos bancos de pruebas y se realizó una serie de experimentos de AF.

Los resultados de esos autores indican que existe una interferencia considerable alrededor de la caja de confluencia. Una interferencia más alta reduce seriamente la tasa de recepción de paquetes del nodo cercano, lo cual es una restricción importante para implementar sensores inalámbricos en AF. Finalmente, en este trabajo se proponen nuevos retos y futuras oportunidades de investigación.

La hormiga roja de fuego *Solenopsis invicta* es una especie invasora destructiva que se ha extendido por todo el mundo. La detección temprana de nidos de *S. invicta* es crítica para un monitoreo y control efectivo en las regiones invadidas por este insecto. El estudio de Su et al. (2023) presenta un novedoso sistema de vigilancia de nidos de *S. invicta* que combina la IA y perros robóticos.

El sistema fue diseñado con algoritmos de reconocimiento inteligente para identificar con precisión los nidos de estas hormigas. Con una tasa de precisión del 95%, el sistema brindó una detección eficiente de nidos de *S. invicta* con mayor sensibilidad y bajas tasas de faltantes y descubrimientos falsos, lo que puede ayudar o incluso reemplazar a los humanos en la localización y aplicación de pesticidas a los nidos de hormigas bravas en campos abiertos para lograr resultados efectivos sobre el control de esta plaga invasora.

Rahman y Ravi (2022) mencionan que según la ONU las plagas causan entre 20 y 40% de las pérdidas en la producción agrícola mundial cada año, y el uso excesivo de pesticidas para controlar las plagas genera graves problemas. Por eso, se ya se desarrollaron aplicaciones como Plantix, Leaf-Byte, Bioleaf, Cotton Ace, Apizoom, etc., para diagnosticar, identificar y controlar plagas de insectos. Por lo tanto, la integración de la IA con la entomología ayudará en el manejo y pronóstico efectivo y oportuno de plagas y enfermedades.

La detección y control temprano de fitoenfermedades es fundamental para evitar pérdidas en el rendimiento y la calidad del producto agrícola. Los estudios de las enfermedades de las plantas han sido investigados para detectar anomalías en

el crecimiento vegetal mediante el monitoreo de plantas y la detección de patógenos para garantizar la agricultura sustentable. Sin embargo, es muy difícil monitorear las enfermedades de las plantas manualmente, ya que se requiere mano de obra, una detección precisa y en tiempo real.

En el reporte de Algubelly et al. (2020) se señala que el procesamiento de datos se usa para la detección de enfermedades de las plantas que involucran la adquisición de imágenes, preprocesamiento, segmentación, extracción de características y su clasificación. En este trabajo, los autores proponen un algoritmo de procesamiento de imágenes basado en IA para detectar de manera remota enfermedades en plantas de Chile. El sistema propuesto incluía ResNet CNN para la extracción y clasificación de características fenotípicas.

INTELIGENCIA ARTIFICIAL CONTRA LA MOSQUITA BLANCA

Un método bien conocido para evaluar la resistencia de las plantas a los insectos es midiendo la reproducción o la oviposición de los insectos. Las moscas blancas son vectores de enfermedades virales económicamente importantes y, por lo tanto, ampliamente estudiadas. En un experimento realizado por Devi et al. (2023), las moscas blancas se colocaron en las plantas utilizando jaulas con clip, donde pusieron cientos de huevos en unos pocos días. Al cuantificar los huevos de mosca blanca, la mayoría de los investigadores realizan mediciones oculares manuales utilizando un microscopio estereoscópico.

En comparación con otros huevos de insectos, los huevos de mosca blanca son muchos y muy pequeños, generalmente de 0.2 mm de largo y 0.08 mm de ancho; por lo tanto, este proceso requiere mucho tiempo y esfuerzo, con y sin conocimiento experto previo. Los experimentos de resistencia a insectos en plantas requieren múltiples réplicas de diferentes accesiones de plantas; por lo tanto, un método automatizado y rápido usando IA para cuantificar huevos de insectos puede ahorrar mucho tiempo y recursos humanos.

Estas estrategias ofrecen una gran promesa para brindar una solución efectiva y sostenible al problema de las moscas blancas, ya sea de forma aislada o en combinación con otras prácticas ampliamente utilizadas bajo los regímenes de manejo integrado de plagas. La sarna bacteriana y las enfermedades virales de las plantas causadas por la mosca blanca representan un problema que llama la atención de los biólogos. Entre las muchas especies de moscas blancas, *B. tabaci* es un insecto capaz de atacar múltiples cultivos, malezas y huéspedes ornamentales, por lo que se requiere el apoyo de la IA para su control.

El clasificador de bosque aleatorio empleado por Kalpana y Senguttuvan (2022), se

utiliza para clasificar los tres niveles de imágenes infectadas por la mosca blanca en espiral, ya que el valor de precisión para el conjunto de prueba es del 97.5% en comparación con las redes neuronales y la regresión logística multinomial. Los autores concluyen diciendo que la clasificación de imágenes usando un clasificador de bosque aleatorio mejorará el sistema de aviso de plagas en tiempo real para la mosca blanca en espiral de las plantaciones de palma cocotera.

A pesar de ser una plaga de importancia mundial, el manejo eficaz de las moscas blancas mediante la implicación de enfoques respetuosos con el ambiente sigue siendo una tarea de largo alcance. Saurabh et al. (2021) señalan que hay diversas estrategias de control con tecnología de punta como el uso de la IA, la interferencia de ARN y las modificaciones genéticas de las plantas para la expresión de proteínas contra la mosca blanca (Figura 30).



Figura 30. Adultos y huevecillos de mosquita blanca (*Bemisia tabaci*) transmisoras de geminivirus. Esta es una de las plagas más importantes y extendidas en todo el mundo; tiene un gran número de huéspedes y ha adquirido resistencia a los plaguicidas; ataca a cultivos hortícolas y muchos otros en agroecosistemas tropicales y subtropicales de todo el mundo. (Tomado de: <https://fagro.mx/productos/problemas-fitosanitarios/mosquita-blanca>).

El pequeño tamaño de las mosquitas blancas, su capacidad para reproducirse rápidamente y sus habilidades para moverse en distancias relativamente cortas, contribuyen a poner a varios huéspedes potenciales en riesgo de infestación. La protección de las plantas contra estos insectos es fundamental para aumentar la cantidad y la calidad de los cultivos.

Mahmoudi et al. (2023) señalan que una estrategia de protección eficaz contra *B. tabaci* debe partir de la detección e identificación temprana de este tipo de insectos para

saber si se trata de un huevo hembra. En los últimos años, la técnica del aprendizaje profundo y los autocodificadores han dado excelentes resultados en muchas tareas de clasificación de imágenes. Eso permitió a estos autores mejorar la precisión de la clasificación en el campo agrícola y la identificación de huevos de insectos en las plantas.

La agricultura es la principal fuente de la que depende la economía de algunos países. Pakistán es el cuarto mayor productor de algodón del mundo, lo que lo convierte en uno de sus principales cultivos. Soomro et al. (2022) usando un modelo que considera la temperatura, describieron los diferentes fenotipos de plantas de algodón (*Gossypium hirsutum* L.). El estudio se enfocó a desarrollar un sistema que pueda manejar la población de mosca blanca del algodón.

La Figura 31 muestra los resultados de la detección de insectos en el campo. Los resultados del experimento revelan que el algoritmo localiza con precisión el insecto con un mayor nivel de confianza. Además, se calcularon la exactitud, la precisión y la recuperación para evaluar el rendimiento estadístico del modelo matemático.

Utilizando herramientas de IA para la detección de insectos en el campo, Ramalingam et al. (2020) utilizaron 150 imágenes de prueba para cada clase de insecto. Las imágenes se recopilan de la base de datos de imágenes de insectos de campo de la granja y mediante sistemas de aprendizaje profundo se alimentaron los sistemas de detección.

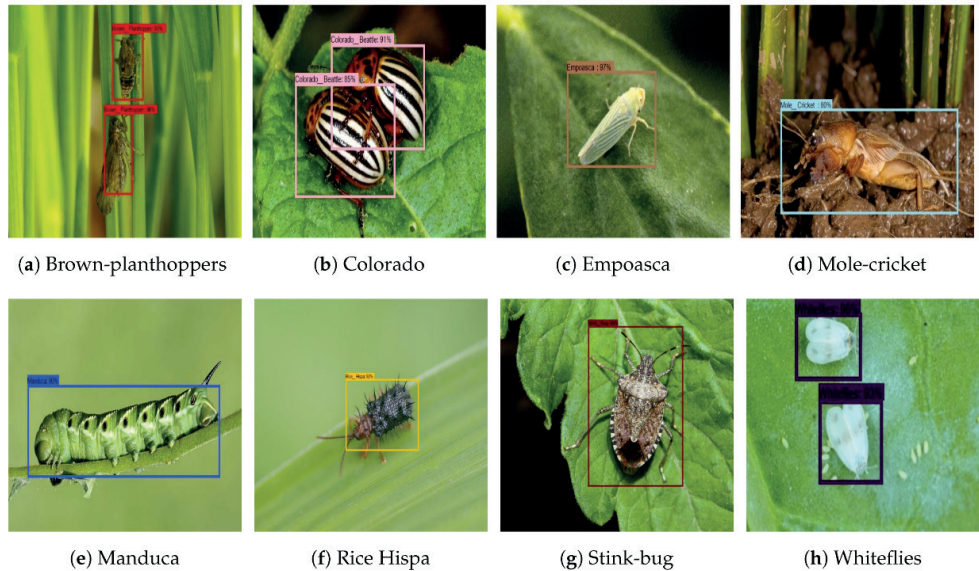


Figura 31. Identificación de insectos de cultivos de campo y en jardines y huertos mediante un algoritmo que permite hacer la detección e identificación de insectos apoyado con una base de datos de imágenes de insectos (Tomado de: Ramalingam et al., 2020).

El principal objetivo de ese trabajo era conocer la población de insectos con sus

huevos y con sus padres. Otro propósito fue obtener información sobre la variedad de algodón con baja población de insectos. Por lo tanto, se podría aumentar el rendimiento del algodón y se deberían usar menos agroquímicos, mejorando así los ingresos de los agricultores. Los autores concluyen que el mejor modelo para predecir moscas blancas en algodón fue ARIMAX, estando su precisión casi a la par con los modelos estadísticos de pronóstico y debido a que ARIMAX es un modelo estadístico, también puede usarse para pronósticos.

El algodón es uno de los productos agrícolas económicamente más importantes del mundo; sin embargo, es susceptible a numerosos ataques de plagas y virus durante la temporada de crecimiento. Las moscas blancas pueden afectar mucho este cultivo, pero la detección oportuna ayudaría a controlar esta plaga. Los modelos de aprendizaje profundo obtenidos son los más adecuados para la clasificación de fitoenfermedades.

Sin embargo, Jajja et al. (2023) indican que la escasez de datos sigue siendo un cuello de botella crítico para las aplicaciones de la visión artificial. Varios modelos de aprendizaje profundo han demostrado resultados notables en la clasificación de enfermedades. Sin embargo, estos modelos se han validado con conjuntos de datos pequeños que no son confiables por no ser representativos de todo el cultivo. En este estudio, los autores desarrollaron un conjunto de datos sobre hojas atacadas por mosca blanca que contiene 5,135 imágenes divididas en dos clases principales: (i) saludables y (ii) no saludables.

Posteriormente, usaron un enfoque basado en un transformador convolucional compacto (CCT) para clasificar el conjunto de datos de imágenes. Los resultados muestran la efectividad del enfoque CCT en comparación con los enfoques más avanzados, ya que ese modelo logró una precisión de 97.2%, mientras que Mobile Net, ResNet152v2 y VGG-16 lograron precisiones del 95, 92 y 90%, respectivamente.

Por otro lado, el coco (*Cocos nucifera* L.) es un cultivo importante en la economía de la India, país que contribuye con 20% de la producción mundial. La mosca blanca en espiral rugosa es una plaga invasora del cultivo de coco. Esta plaga puede causar una reducción del rendimiento del 15 al 20%. Por lo tanto, existe la necesidad urgente de controlar esta plaga.

El cultivo de coco es una palmera perenne con un amplio rango de distribución a través de islas tropicales y costas. Es una importante fuente de ingresos para 30 millones de agricultores, mientras que 60 millones de hogares dependen de la industria del coco directamente por los trabajadores agrícolas, e indirectamente a través de la distribución, comercialización y procesamiento de coco y productos a base de coco (Salum et al., 2020).

La producción estancada, los materiales de plantación inadecuados, los efectos del

cambio climático, así como las plagas y enfermedades se encuentran entre los problemas clave que deben abordarse con urgencia en la industria mundial del coco. Acorde con Arumugam y Hatta (2022), el genotipado basado en la secuenciación de próxima generación (NGS) y las herramientas de edición del genoma para mejorar el coco, son las biotecnologías en uso. Además, la combinación de estas tecnologías y el mejoramiento acelerado mediante IA, podría acelerar características genéticas deseables en el mejoramiento del coco.

Plant Screen Mobile (PMS), una aplicación móvil que se puede usar en un teléfono Android, tiene el potencial de hacer que el fenotipado de la hoja de coco sea más fácil, rápido y preciso que el método tradicional. Esta aplicación permite a los investigadores estimar el área foliar proyectada, el color del follaje y los parámetros de forma en una variedad de arquitecturas de plantas (Figura 32).

La aplicación de pesticidas químicos es actualmente el principal método efectivo para controlar la mosca blanca del tomate en China y en todo el mundo. En el estudio de Mao et al. (2022) se evaluó la eficacia en el control de *B. tabaci* de tres insecticidas sistémicos: tiametoxam, sulfoxaflor y ciantraniliprol, con los que se empapó el suelo antes del trasplante durante todo el período de crecimiento del tomate en dos invernaderos de tomate en los suburbios de Beijing, China, durante 2018 y 2019.

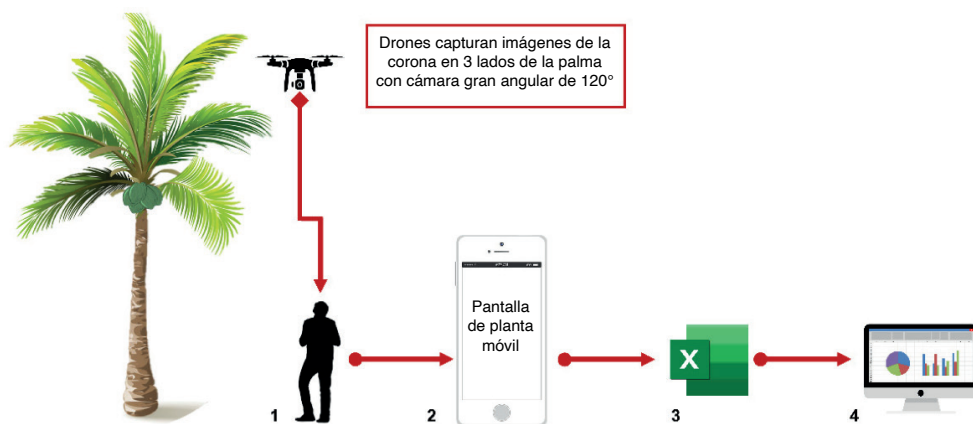


Figura 32. Empleo de la inteligencia artificial en mejoramiento del coco. (1) Se utiliza UAV o drones para capturar la imagen de la corona en tres lados (para cámara con gran angular de 120°). (2) La imagen se transfiere a la carpeta Plant Screen Mobile App (PMS). (3) El área foliar total se genera automáticamente en formato CSV. (4) Análisis de datos relevantes para obtener las observaciones deseadas (Tomado de: Arumugam y Hatta, 2022).

Todos los frutos de tomate tratados químicamente tenían residuos de insecticida aceptables que eran inferiores a los límites máximos de residuos correspondientes. Los resultados sugieren que la aplicación de tiametoxam 25% WDG a una tasa de 21 g i.a./hm², sulfoxaflor 22% AS a 18 g i.a./hm² o ciantraniliprol 10% OD a 18 g i.a./hm², se podrían

recomendar junto con redes anti-insectos para controlar a *B. tabaci* durante el ciclo de crecimiento del tomate, como parte de los programas de MIP en China.

INTELIGENCIA ARTIFICIAL CONTRA TRIPS

Las especies de trips de la familia *Thripidae* son polífagas y contienen plagas clave de una gran variedad de plantas ornamentales y vegetales en todo el mundo, incluidos los trips de las flores occidentales (*Frankliniella occidentalis*), los trips de la cebolla (*Thrips tabaci*) y los trips del melón (*Thrips palmi*), todos los cuales de alguna manera han generado resistencia a los plaguicidas (Srinivasan et al., 2018).

En el reporte de Mouden y Leiss (2021) se menciona que además del daño directo por alimentación, estos pequeños insectos (Figura 33) son vectores de virus, de los cuales el virus del marchitamiento del tomate (TSWV) es el económicamente más importante y nefasto (Reitz et al., 2020).



Figura 33. Hembra adulta de del trips predator *Aeolothrips intermedius* que junto con (*T. tabaci*), son unas de las plagas polífagas más dañinas de muchos cultivos extensivos en todo el mundo (Tomado de: Abenaim et al., 2022).

La clasificación de especies de plagas microscópicas similares ha recibido poca atención en la literatura, y es el objetivo de este estudio como un medio para abordar la necesidad del manejo de plagas agrícolas. Amarathunga et al. (2022) propusieron un método novedoso de IA para la clasificación detallada de insectos microscópicos basada en el aprendizaje profundo utilizando la arquitectura Vision Transform (ViT), la cual emplea

un mecanismo de atención basado en el conocimiento del dominio.

El enfoque de IA propuesto consta de dos módulos principales: (i) uno de pre procesamiento de datos para segmentar las características relevantes del insecto y dividirlo en segmentos del cuerpo para informar la identificación, y (ii) un modelo apilado basado en el conocimiento del dominio basado en ViT, para generar la predicción de cada segmento del cuerpo y para fusionar predicciones para cada segmento en una clasificación precisa a nivel de especie. El modelo se evaluó con buenos resultados, el enfoque utilizó un conjunto de datos de imágenes de dos especies de trips económicamente devastadoras: los trips de las flores occidentales (*F. occidentalis*) y los trips de la peste (*Thrips imaginis*).

Por su parte, el banano orgánico es uno de los productos más populares a nivel mundial y su popularidad se debe principalmente a sus excelentes propiedades nutricionales y exquisito sabor. El Perú es considerado uno de los principales productores y exportadores de este producto, siendo la ciudad de Piura la principal región con la mayor cantidad de los agroproductores nacionales. También se considera un factor clave en el desarrollo de la economía de esta región, ya que genera oportunidades de trabajo debido a la cadena productiva requerida en el proceso (cosecha, poscosecha y exportación).

Como alternativa, Texeira et al. (2023) han ideado el MIP haciendo una detección automática usando IA y técnicas de aprendizaje profundo, lo que permite mejorar el control de plagas, disminuir el uso excesivo de pesticidas y mejorar la producción y la calidad de los cultivos. Con las mejoras en las tecnologías de IA, han surgido varias aplicaciones, incluida la detección automática de plagas, el monitoreo de imágenes y la identificación de insectos con diversos tipos de trampas (Figura 34).




Figura 34. Dispositivos instalados en campo para coleccionar imágenes de trampas y las respectivas imágenes recolectadas. (a) Trampa de feromonas en un viñedo para atraer polillas de la uva; (b) trampas pegajosas amarillas instaladas para detectar polillas de dorso de diamante; (c) trampa de luz para atraer 24 clases principales de plagas (Tomado de: Texeira et al., 2023).

El principal problema que enfrentan los productores de banano es la existencia de plagas como Trips de la mancha roja, Sigatoka negra y otras, que afectan la producción y la calidad del producto final. Por lo tanto, Manrique-Silupu et al. (2021) propusieron una alternativa utilizando la tecnología de la Industria 4.0, así como la instalación de una red de sensores IoT en las plantaciones de banano para desarrollar un modelo de IA que estime la clasificación del nivel de incidencia de plagas basado en técnicas de aprendizaje automático.

La implementación de este sistema ayuda a los productores a mejorar el control de plagas, al programar las fechas de fumigación de manera más efectiva, optimizando no solo la calidad del producto, sino también reduciendo los costos del paquete tecnológico.

Por otro lado, el objetivo de estudio de Tay et al. (2021) fue desarrollar un sistema innovador de IA para evaluar el riesgo de plagas utilizando un enfoque de lógica difusa. El sistema está diseñado para proporcionar a los agricultores un índice que representa una estimación del riesgo de presencia del thrips de las flores (WFT), *F. occidentalis* en un invernadero de rosas.

El principal hallazgo de esta investigación se resume en cuatro puntos. (i) En primer

lugar, el modelo se basa en variables medidas automáticamente a través de sensores y no requiere actividad humana. (ii) En segundo lugar, como el sistema no solo está orientado a los centros de investigación, sino también a los agricultores, el fenómeno del conteo manual podría ser reemplazado por un valor predictivo. (iii)

Además, la novedad asociada con el sistema es que proporciona una estimación diaria del nivel de riesgo de WFT, en lugar de semanal. Al hacerlo, los agricultores podrían estar al tanto de la influencia de las condiciones climáticas diarias en su evolución. (iv) Finalmente, este estudio podría ser beneficioso para ayudar a reducir el uso de pesticidas y disminuir el porcentaje de pérdidas, debido al monitoreo continuo con IA del nivel de riesgo en el invernadero.

Los agricultores de la India enfrentan muchos desafíos. Cada año, sufren pérdidas debido a la infestación de insectos agrícolas. Estas pérdidas son principalmente el resultado de una vigilancia de campo inadecuada, enfermedades de los cultivos y un manejo ineficaz de los plaguicidas.

Acorde con Singh et al. (2022), se necesita tecnología de punta en constante evolución para mantener el control sobre estas plagas responsables de las reducciones en la producción año tras año. La IA mediante las redes de sensores inalámbricos abordan todos estos problemas; de hecho, la tecnología de red de sensores inalámbricos se está convirtiendo rápidamente en la columna vertebral de la agricultura moderna de precisión.

Por eso, estos autores propusieron una estrategia para el monitoreo de plagas usando redes de sensores inalámbricos, reconociendo el comportamiento de los insectos usando varios sensores. El enfoque rápido y preciso de detección y categorización de insectos fue basado en cinco cultivos importantes, sus plagas asociadas y examinando el comportamiento de los insectos mediante la recopilación de datos de sensores colocados en el campo. Los resultados muestran que se mejora la precisión del trabajo en 3.9%.

Los trips son plagas que causan daño al succionar la savia de las plantas y al transmitir varios tospovirus, ilarvirus, carmovirus, sobemovirus y machlomovirus. La identificación precisa y oportuna es la clave para el manejo exitoso de las especies de trips. Sin embargo, su pequeño tamaño, presencia de color, y la variabilidad genética intraespecífica, hacen que la identificación de las especies de trips sea un gran desafío.

El estudio de Gosh et al. (2021) señala que el uso de plataformas de detección molecular y electrónica mediante IA ha hecho que la identificación de trips sea rápida, precisa, sensible, de alto rendimiento e independiente de las etapas de desarrollo. Los marcadores de microsatélites: RFLP, RAPD, AFLP y CAPS, han ayudado a explicar la estructura de la población, el flujo de genes y la heterogeneidad dentro de las especies.

Se han empleado técnicas recientes como LAMP y RPA para la identificación sensible e *in situ* de trips. Además, las redes neuronales artificiales y los diagnósticos de alto rendimiento facilitan la identificación automatizada.

INTELIGENCIA ARTIFICIAL CONTRA GUSANO COGOLLERO

Spodoptera frugiperda (el gusano cogollero) causa daños irreversibles en los cultivos de algodón, y su inspección visual en las plantas es una tarea onerosa para los humanos. Una estrategia reciente de IA para realizar automáticamente tareas similares es procesar mediciones de reflectancia hiperespectral con algoritmos de aprendizaje automático. Ramos et al. (2022) propusieron modelar la respuesta espectral de las plantas de algodón bajo los ataques del gusano cogollero utilizando algoritmos de aprendizaje automático, que culmina en la creación de un modelo teórico basado en la simulación de bandas.

Se evaluaron varios algoritmos y se adoptó un enfoque de clasificación para identificar las longitudes de onda que más contribuyeron a detectar el daño. Se encontró que el algoritmo Random Forest produjo el modelo más adecuado, y el último día de análisis fue mejor para separar plantas sanas y dañadas (medida F: 0.912). Las mejores regiones espectrales van desde el rojo hasta el infrarrojo cercano (650 a 1350 nm) y el infrarrojo de onda corta (1570 a 1640 nm). El modelo propuesto contribuye a identificar con precisión plantas de algodón bajo el ataque de *S. frugiperda*, tanto para escalas hiperespectrales como multiespectrales.

Actualmente las personas están más preocupadas por alimentos de buena calidad y más saludables. Por lo tanto, las industrias globales de producción y procesamiento de alimentos, tienen gran interés en las tecnologías de IA y aprendizaje automático (ML) para mejorar la calidad de los alimentos en los principales cultivos.

La IA y el ML se aplican en los sectores agrícolas para proteger los cultivos de campo de los ataques de plagas. Kasinathan y Uyyala (2023) reportan que el gusano cogollero (FAW) del maíz (Figura 35) es uno de los insectos más devastadores que causa una infestación severa en cultivos importantes reduciendo su rendimiento. La inspección manual de los insectos FAW es fundamental cuando se trata de insectos similares, como el barrenador del maíz y el gusano cogollero, pero las imágenes RGB hiperespectrales son mucho mejores.

Los resultados de la detección de insectos FAW mostraron que se tuvo una precisión promedio del 94.21% en el modelo Mask R-CNN con la red troncal Resnet-101, lo que demuestra la eficacia del modelo generado para la segmentación de insectos FAW en los cultivos de campo con maíz y otros cultivos.



Figura 35. Imágenes que muestran el conjunto de prueba que contienen imágenes de insectos FAW, así como sin insectos FAW. Las imágenes RGB FAW se redimensionaron a 640×640 píxeles para entrenar el modelo (Tomado de: Kasinathan y Uyyala (2023).

El gusano cogollero (FAW), *S. frugiperda* invadió China en 2019, lo que ha amenazado seriamente la seguridad de la producción de alimentos en ese país y suscitó preocupaciones. Como una nueva tecnología de aplicación de bajo volumen, un sistema de fumigación aérea no tripulado (UASS) por drones está siendo importante en el control de FAW en China.

Sin embargo, los estudios sobre el efecto del volumen de aplicación de agua sobre la eficacia de FAW usando UASS han sido limitados. En el estudio de Shan et al. (2022) se utilizaron tarjetas Kromekote® para muestrear la deposición. Se evaluaron cuatro volúmenes de aplicación de agua (7.5, 15.0, 22.5 y 30.0 L/ha) y se utilizó un control para comparación. La eficacia del control se evaluó a los 1, 3, 7 y 14 días después del tratamiento (DAT).

Los resultados mostraron que los métodos de muestreo tienen un efecto significativo en los resultados de la deposición. La eficacia de deposición y control aumentó gradualmente a medida que aumentaba el volumen de aplicación de agua. La eficacia de control a los 14 DDT bajo diferentes volúmenes de aplicación de agua, estuvo en el rango de 59.4–85.4%. Estos datos sugieren que la fumigación con UASS o drones y usando IA, se puede lograr un control satisfactorio del gusano cogollero en el campo.

Para permitir la adquisición remota de imágenes y la transmisión inalámbrica de *S. frugiperda* para el seguimiento de señuelos sexuales en el campo, se diseñó un módulo de procesador de CPU, un módulo de fuente de alimentación, un módulo de adquisición de imágenes, un módulo de transmisión de red inalámbrica 4G y un módulo SRAM externo.

Ese sistema diseñado por Chang et al. (2022) emplea el núcleo de control STM32F407, la cámara OV2640 para la adquisición de imágenes, el algoritmo JPEG para comprimir y decodificar los datos de imágenes recopilados por la cámara y restaurar automáticamente la imagen recopilada en el punto de monitoreo.

Los resultados experimentales muestran que el sistema logra la adquisición remota de imágenes de las polillas de los pastizales y transmite de manera confiable los datos de imágenes recopilados al lado del servidor de la computadora a través de una red inalámbrica 4G, lo que permite que en el monitor se vean imágenes de los puntos de monitoreo de las polillas recopilados por el sistema en tiempo real y guarde los datos de imagen recopilados localmente. Este sistema logra la automatización y la IA del sistema de monitoreo, prepara los datos para la investigación posterior y tiene una amplia aplicación para el monitoreo poblacional.

El experimento de Rui et al. (2022) utilizó el modelo de análisis estadístico Maxent para predecir la localización de *S. frugiperda* en la provincia china de Yunnan incluyendo varias ciudades. *S. frugiperda* se originó en los climas tropicales y subtropicales de las Américas.

Es una plaga agrícola importante que preocupa a la ONU. Evaluar la mejor región apropiada del gusano puede brindar relevante información vital para la formulación de acciones de control y alerta temprana. El resultado revela que el área de *S. frugiperda* se reubicará al sur del área de investigación y continuará hasta al menos el año 2040.

S. frugiperda es una plaga polífaga que causa pérdidas significativas a los cultivos agrícolas. Las orugas o gusanos se alimentan de hojas, tallos y partes reproductivas de más de 100 especies de plantas que incluye maíz, arroz, sorgo, caña de azúcar, col, remolacha, cacahuete, soya, alfalfa, cebolla, tomate, papa y algodón. En Brasil, *S. frugiperda* causa hasta el 34% de reducción en el rendimiento de grano de maíz y eso asciende a una pérdida anual de US\$ 400 millones.

La detección visual de plantas dañadas es una tarea ardua para la inspección humana de *S. frugiperda*, la información espectral relacionada con el daño de las plantas registrada en una escala espectral, puede ser útil. Estas medidas, asociadas a técnicas de aprendizaje automático, producen información útil para el desarrollo de métodos de inspección rápidos y no invasivos. Se evaluaron diferentes modelos de aprendizaje automático y el mejor modelo general se definió mediante comparaciones de precisión en un conjunto de prueba (Kasinathan y Uyyala, (2023).

En el estudio de Ganiger et al. (2018) se reporta que *S. frugiperda* representa anualmente pérdidas de cultivos superiores a los 500 millones de dólares en la zona de sureste de USA y la costa atlántica para el cultivo de maíz y otros cultivos de grano. La Figura 36 muestra diversas etapas en el desarrollo de este insecto, la masa de huevos; caracteres larvales; así como los cuerpos del macho y la hembra.

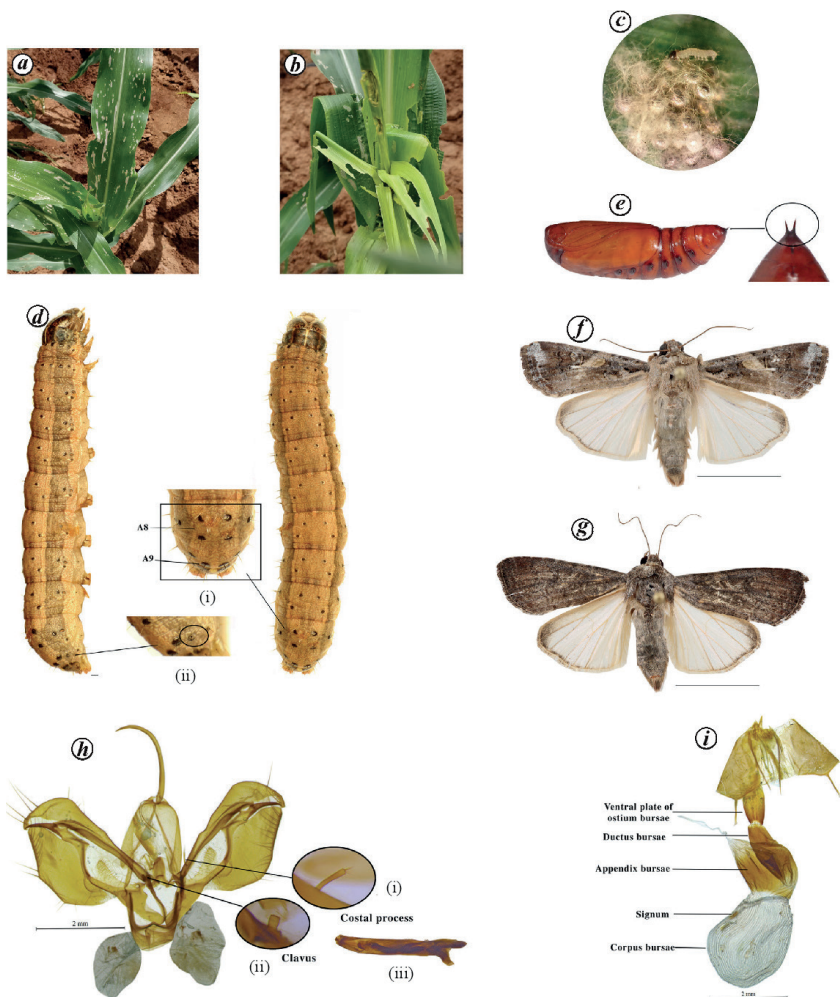


Figura 36. (a), Etapa temprana de alimentación; (b), etapa posterior de alimentación; c, masa de huevos; d, caracteres larvales; e, carácter pupal; (f), macho de *Spodoptera frugiperda*; (g), Hembra de *S. frugiperda*; (h), genitales masculinos; y/o, genitales femeninos (Tomado de Ganiger et al., 2018).

CONCLUSIONES

Debido al deseo de aumentar la productividad mediante el control de plagas y enfermedades, así como la escasez de trabajadores disponibles, la agricultura inteligente de la nueva revolución verde, está recibiendo mucha atención para apoyar con la IA en la solución de la problemática causada por las plagas y enfermedades en cultivos agrícolas.

En particular en la literatura científica se prefiere a la tecnología de redes neuronales artificiales con dispositivos IoT personalizados para maximizar la productividad y eficiencia; de manera que ya se realizaron pronósticos de rendimiento y control automático del entorno usando modelos de aprendizaje automático con diferentes combinaciones de datos.

Tecnologías como el manejo climático autónomo del invernadero con IA, la detección de enfermedades y plagas, y la predicción de su aparición, ayuda a los agricultores a reducir las pérdidas de los cultivos al hacerse cargo de las limitaciones humanas.

Por lo tanto, el potencial de aplicación de la IA en el proceso de identificación de especies patógenas, en determinar las variables agroclimáticas en tiempo real que inciden sobre el desarrollo de plagas y enfermedades en la agricultura de campo abierto, así como en condiciones protegidas, que utiliza redes neuronales artificiales y herramientas de aprendizaje profundo, es la tecnología de avanzada que apoyará el control de plagas y enfermedades.

LITERATURA CITADA

- Abenaim, L., Bedini, S., Greco, A., Giannotti, P. y Conti, B. (2022). Predation capacity of the banded *Thrips Aeolothrips intermedius* for the biological control of the onion thrips *Thrips tabaci*. *Insects*, 13(8), 702.
- Algubelly, Y.R., Nadipelli, A. y Pasam, M. (2020). Disease detection in chilli plants and remote monitoring of agricultural parameters using CNN. *Journal of Critical Reviews*, Vol 07, No, 07.
- Amarathunga, D.C., Ratnayake, M.N., Grundy, J. y Dorin, A. (2022). Fine-grained image classification of microscopic insect pest species: Western flower thrips and plague thrips. *Computers and Electronics in Agriculture*, 203, 107462.
- Amrillojonovich, R. U. (2023). Detect diseases in plants using artificial intelligence. *Spectrum Journal of Innovation, Reforms and Development*, 15, 42-50.
- Arumugam, T. y Hatta, M.A.M. (2022). Improving coconut using modern breeding technologies: Challenges and Opportunities. *Plants*, 11(24), 3414.
- Ayan, E. (2023). Genetic algorithm-based hyperparameter optimization for convolutional neural networks in the classification of crop pests. *Arabian Journal for Science and Engineering*, 1-15.
- Chang, J., Xu, Q., Lu, Y. y Zhang, H. (2022, December). Remote image acquisition system based on STM32 for *Spodoptera frugiperda*. In 2022 IEEE 5th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC) (Vol. 5, pp. 885-890). IEEE.
- da Cunha, V.A.G., Costa, L., Ampatzidis, Y., Pullock, D., Weldon, C., Kruger, K. y Manrakhan, A. (2022). Automatic pest detection utilizing machine vision and artificial intelligence. In 2022 ASABE Annual International Meeting (p. 1). American Society of Agricultural and Biological Engineers.
- Devi, M.G., Rustia, D.J.A., Braat, L., Swinkels, K., Espinosa, F.F., van Marrewijk, BM. y Caarls, L. (2023). Eggsplore: a rapid plant-insect resistance determination tool using an automated whitefly egg quantification algorithm. *Plant Methods*, 19(1), 49.
- Ganiger, P.C., Yeshwanth, H.M., Muralimohan, K., Vinay, N., Kumar, A.R.V. y Chandrashekara, K. (2018). Occurrence of the new invasive pest, fall armyworm, *Spodoptera frugiperda* (JE Smith) (Lepidoptera: Noctuidae), in the maize fields of Karnataka, India. *Current Science*, 115(4), 621-623.
- Ghosh, A., Jangra, S., Dietzgen, R.G. y Yeh, W.B. (2021). Frontiers approaches to the diagnosis of thrips (Thysanoptera): How effective are the molecular and electronic detection platforms?. *Insects*, 12(10), 920.
- Gupta, V.A., Padmavati, M.V., Saxena, R.R., Patnaik, P.K. y Tamrakar, R.K. (2023). A study on image processing techniques and deep learning techniques for insect identification. *Karbala International Journal of Modern Science*, 9(2), 16.
- Hanif, M.K., Khan, S.Z. y Bibi, M. (2023). Applications of artificial intelligence in pest management. In *Artificial Intelligence and Smart Agriculture Applications* (pp. 277-300). Auerbach Publications.
- Huang, K., Shu, L., Li, K., Chen, Y., Zhu, Y. y Valluru, R. (2023). Sustainable and intelligent phytoprotection in photovoltaic agriculture: New Challenges and Opportunities. *Electronics*, 12(5), 1221.

Jajja, A.I., Abbas, A., Khattak, H.A., Niedbala, G., Khalid, A., Rauf, H.T. y Kujawa, S. (2022). Compact convolutional transformer (CCT)-based approach for whitefly attack detection in cotton crops. *Agriculture*, 12(10), 1529.

Kalfas, I., De Ketelaere, B., Bunkens, K. y Saeys, W. (2023). Towards automatic insect monitoring on witloof chicory fields using sticky plate image analysis. *Ecological Informatics*, 75, 102037.

Kalpana, M. y Senguttuvan, K. (2022, April). Artificial intelligence for on-site detection of invasive rugose spiralling whitefly in coconut plantation. In *Smart Intelligent Computing and Applications, Volume 1: Proceedings of Fifth International Conference on Smart Computing and Informatics (SCI 2021)* (pp. 413-420). Singapore: Springer Nature Singapore.

Kalpana, M. y Senguttuvan, K. (2022, April). Artificial intelligence for on-site detection of invasive rugose spiralling whitefly in coconut plantation. In *Smart Intelligent Computing and Applications, Volume 1: Proceedings of Fifth International Conference on Smart Computing and Informatics (SCI 2021)* (pp. 413-420). Singapore: Springer Nature Singapore.

Kasinathan, T. y Uyyala, S.R. (2023). Detection of fall armyworm (*Spodoptera frugiperda*) in field crops based on mask R-CNN. *Signal, Image and Video Processing*, 1-7.

Mahmoudi, S., Nhidi, W., Bennour, C., Ben Belgacem, A. y Ejbal, R. (2023, June). An intelligent approach to identify the eggs of the insect *Bemisia tabaci*. In *Intelligent Systems Design and Applications: 22nd International Conference on Intelligent Systems Design and Applications (ISDA 2022) Held December 12-14, 2022-Volume 4* (pp. 62-70). Cham: Springer Nature Switzerland.

Manrique-Silupu, J., Campos, J.C., Paiva, E. y Ipanaqué, W. (2021). Thrips incidence prediction in organic banana crop with machine learning. *Heliyon*, 7(12), e08575.

Martins Crispi, G., Valente, D.S.M., Queiroz, D.M.D., Momin, A., Fernandes-Filho, E.I. y Picanço, M.C. (2023). Using deep neural networks to evaluate leafminer fly attacks on tomato plants. *AgriEngineering*, 5(1), 273-286.

Mao, L., Zhang, L., Wang, S., Zhang, Y., Zhu, L., Jiang, H. y Liu, X. (2022). Application of insecticides by soil drenching before seedling transplanting combined with anti-insect nets to control tobacco whitefly in tomato greenhouses. *Scientific Reports*, 12(1), 15939.

Mendoza, Q.A., Pordesimo, L., Neilsen, M., Armstrong, P., Campbell, J. y Mendoza, P.T. (2023). Application of machine learning for insect monitoring in grain facilities. *AI*, 4(1), 348-360.

Mouden, S. y Leiss, K.A. (2021). Host plant resistance to thrips (Thysanoptera: Thripidae)—current state of art and future research avenues. *Current Opinion in Insect Science*, 45, 28-34.

Ozdemir, D. y Kunduraci, M.S. (2022). Comparison of deep learning techniques for classification of the insects in order level with mobile software application. *IEEE Access*, 10, 35675-35684.

Rahman, S.M. y Ravi, G. (2022). Role of artificial intelligence in pest management. *Current Topics in Agricultural Sciences Vol. 7*, 64-81.

Ramalingam, B., Mohan, R.E., Pookkuttath, S., Gómez, B.F., Sairam Borusu, C.S.C., Wee Teng, T. y Tamilselvam, Y.K. (2020). Remote insects trap monitoring system using deep learning framework and IoT. *Sensors*, 20(18), 5280.

- Ramos, A.P.M., Gomes, F.D.G., Pinheiro, M.M.F., Furuya, D.E.G., Gonçalves, W.N., Junior, J.M. y Osco, L.P. (2022). Detecting the attack of the fall armyworm (*Spodoptera frugiperda*) in cotton plants with machine learning and spectral measurements. *Precision Agriculture*, 23(2), 470-491.
- Refaai, M.R., Dattu, V.S., Gireesh, N., Dixit, E., Sandeep, C.H. y Christopher, D. (2022). Application of IoT-based drones in precision agriculture for pest control. *Advances in Materials Science and Engineering*, 2022.
- Reitz, S.R., Gao, Y., Kirk, W.D., Hoddle, M.S., Leiss, J. y Funderburk, J.E. (2020). Invasion biology, ecology, and management of western flower thrips. *Annu Rev Entomol*, 65 (2020), pp. 17-37.
- Rui, Z., Ying, L., Yuan, X. y Mei, C. (2022, November). Predicting the future suitable area of *Spodoptera frugiperda* in the Central and Eastern Parts of Yunnan Province, China, Using the Maxent Statistics Learning Model. In 2022 International Conference on Computers and Artificial Intelligence Technologies (CAIT) (pp. 38-41). IEEE.
- Salum, U., Foale, M., Biddle, J., Bazrafshan, A. y Adkins, S. (2020). Towards the sustainability of the "tree of life": An Introduction. In *Coconut Biotechnology*; Springer: Cham, Switzerland, 2020; pp. 1–15.
- Sarkar, P., Basak, P., Panda, C. S., Gupta, D. S., Ray, M. y Mitra, S. (2023). Prediction of major pest incidence in Jute crop based on weather variables using statistical and machine learning models: A case study from West Bengal. *Journal of Agrometeorology*, 25(2).
- Saurabh, S., Mishra, M., Rai, P., Pandey, R., Singh, J., Khare, A. y Singh, P. K. (2021). Tiny flies: a mighty pest that threatens agricultural productivity—a case for next-generation control strategies of whiteflies. *Insects*, 12(7), 585.
- Shan, C., Wu, J., Song, C., Chen, S., Wang, J., Wang, H. y Lan, Y. (2022). Control efficacy and deposition characteristics of an unmanned aerial spray system low-volume application on corn fall armyworm *Spodoptera frugiperda*. *Frontiers in Plant Science*, 13, 1895.
- Shin, J., Mahmud, M., Rehman, T.U., Ravichandran, P., Heung, B. y Chang, Y.K. (2023). Trends and prospect of machine vision technology for stresses and diseases detection in precision agriculture. *AgriEngineering*, 5(1), 20-39.
- Singh, K.U., Kumar, A., Raja, L., Kumar, V., Vashney, N. y Chhetri, M. (2022). An artificial neural network-based pest identification and control in smart agriculture using wireless sensor networks. *Journal of Food Quality*, 2022.
- Soomro, A.M., Naeem, A.B., Shahzad, K., Madni, A.M., Del Mundo, A.D., Sajid, M. y Baloch, M.A. (2022). Forecasting cotton whitefly population using deep learning. *Journal of Computing & Biomedical Informatics*, 4(01), 64-76.
- Srinivasan, R., Abney, M. R., Lai, P. C., Culbreath, A. K., Tallury, S. y Leal-Bertioli, S. C. (2018). Resistance to thrips in peanut and implications for management of thrips and thrips-transmitted orthotospoviruses in peanut. *Frontiers in plant science*, 9, 1604.
- Su, X., Shi, G., Zhong, J., Li, Y., Dai, W., Xu, G. y Yan, Z. (2023). Use of artificial intelligence for automated detection and surveillance of red imported fire ants nests. *bioRxiv*, 2023-05.
- Tay, A., Lafont, F., Balmat, J. F., Pessel, N. y Lhoste-Drouineau, A. (2021). Decision support system for western flower thrips management in roses production. *Agricultural Systems*, 187, 103019.

Teixeira, A.C., Ribeiro, J., Morais, R., Sousa, J.J. y Cunha, A. (2023). A Systematic review on automatic insect detection using deep learning. *Agriculture*, 13(3), 713.

Toscano-Miranda, R., Toro, M., Aguilar, J., Caro, M., Marulanda, A. y Trebilcok, A. (2022). Artificial-intelligence and sensing techniques for the management of insect pests and diseases in cotton: A systematic literature review. *The Journal of Agricultural Science*, 160(1-2), 16-31.

INTELIGENCIA ARTIFICIAL EN PRODUCCIÓN DE FRUTALES

INTRODUCCIÓN

Recientemente ha cambiado mucho el manejo agronómico en huertos de árboles frutales y viñedos por la inserción y adopción de diversas técnicas de inteligencia artificial (IA) que incluyen algoritmos, usados para determinar el estado hídrico de las plantas mediante sensores que permiten realizar un manejo sustentable del agua con sistemas de microirrigación (Mohammed et al., 2023). En este sentido, el artículo de Navya y Sudha (2023) describe que mediante la internet de las cosas (IoT) y robots manipulados con IA, se pueden realizar tareas diversas como el manejo de los sistemas hídricos, la aspersión al follaje de agroquímicos y la cosecha de frutos.

Acorde con Lee y Tardaguila (2023) las tecnologías del siglo XXI usadas en la detección y manejo de enfermedades de plantas y frutales incluyen: robots de detección mediante IA, visión por computadora, elaboración de imágenes multiespectrales e hiperespectrales, termografía, espectroscopia, fluorescencia de clorofila, compuestos orgánicos volátiles de plantas, nanosensores y biosensores. Pero aún se necesitan métodos confiables, fáciles de usar y que se tenga el apoyo e interés conjunto de los fruticultores y la industria.

INTELIGENCIA ARTIFICIAL EN VIÑEDOS Y LA VITICULTURA

Las uvas son la quinta fruta más producida, con 79.5 millones de toneladas al año en todo el mundo durante el 2019. La estimación de la madurez de las bayas es fundamental para determinar el momento adecuado de la cosecha, lo que a su vez se traduce en una calidad favorable para uva de mesa o vino (Shah et al., 2020).

Las técnicas tradicionales para estimar el peso de los racimos de uva consisten en contar manualmente la variedad de racimos por cepa en un subconjunto del viñedo, y escalar mediante toda la variedad de cepas. Este método puede ser arduo, costoso y su precisión depende de la escala de la muestra.

Para superar estos problemas, Kanhayyalal y Jadhav (2023) propusieron un sistema de predicción del rendimiento de viñedos basado en visión artificial y aprendizaje profundo (DL). Los conjuntos de datos autopreparados se utilizaron para el análisis comparativo de los sistemas de predicción de rendimiento 2D y 3D para viñedos. El DL para la operación de segmentación en un conjunto de datos de imagen RGB-D creado con la cámara D435I se usó junto con la técnica de predicción de peso basada de los racimos de uva presentes en la imagen que se emplea con estos conjuntos de datos.

Esto es muy importante en la producción de vino, donde el momento óptimo de la cosecha determinado por parámetros enológicos afectan la calidad del vino producido. El momento exacto en el que cada grano de uva alcanza su nivel óptimo de madurez depende del suelo, la duración de la temporada de crecimiento, la variedad, la carga de fruta y otras condiciones ambientales (Vaudour, 2002).

La espectroscopia puede contribuir a la evaluación de la calidad de los alimentos y frutos de manera sencilla y económica. Especialmente en la producción de uvas, las regiones visibles de infrarroja cercana (VNIR) e infrarroja de onda corta (SWIR), pueden usarse para dar seguimiento a la madurez de fruta, y para el control de calidad en todas las etapas de madurez.

La Región demarcada del Alto Douro en Portugal es la región vitivinícola más antigua y más regulada del mundo, formada por un ecosistema de valor único que permite el cultivo de la vid en sus característicos viñedos en terrazas. La detección de hileras de vides en viñedos en terrazas constituye una tarea esencial para el logro de importantes objetivos como la evaluación multitemporal de cultivos y la estimación de la producción.

A pesar de los avances e investigaciones en este campo, la mayoría de los estudios se limitan a viñedos planos con hileras rectas. En el estudio de Figueiredo et al. (2023) se presenta un enfoque exploratorio en la agricultura de precisión para la detección automática de hileras de viñedos en terrazas con técnicas de teledetección asociadas a IA como Machine Learning y Deep learning. En la etapa actual los resultados preliminares son alentadores para la detección de hileras de vid en líneas rectas y curvas considerando la complejidad del terreno.

El objetivo del trabajo de Kalopesa et al. (2023) realizado en Grecia, fue la estimación cuantitativa de la madurez de la uva para vino, mediante el uso de un espectrómetro de sonda de contacto de alta precisión que cubre todo el espectro VNIR-SWIR (350-2500 nm). Las cuatro variedades usadas fueron: Chardonnay, Malagouzia, Sauvignon-Blanc y Syrah. Todas las mediciones se realizaron *in situ* y se utilizó un refractómetro para medir el contenido de sólidos solubles totales (°Brix) de las uvas y proporcionando los datos reales del terreno.

Después del desarrollo de la biblioteca de espectros de uva, se usaron cuatro algoritmos de aprendizaje automático: regresión de mínimos cuadrados parciales (PLS); regresión de bosque aleatorio; regresión de vector de soporte (SVR) y redes neuronales convolucionales (CNN).

Los algoritmos junto con métodos de pretratamiento se aplicaron para la predicción del contenido de °Brix a partir de los datos hiperespectrales VNIR-SWIR. Se concluye que

esta metodología podría ser una herramienta valiosa para que los productores de vino tomen decisiones en tiempo real sobre el tiempo de cosecha (Figura 37) y que sea de manera no destructiva.




Figura 37. El empleo de la inteligencia artificial en los viñedos está ayudando a que la cosecha se realice en el huerto cuando las bayas estén maduras adecuadamente, ya que este factor tiene consecuencias muy importantes en la calidad del vino producido. (Tomado de: <https://futuredrinksexpo.com/en/blog/insights-64/how-ai-will-revolutionize-the-future-of-wine-251.htm>).

El proyecto Vinum reportado por Milburn et al. (2023) busca abordar la escasez de mano de obra calificada en los viñedos modernos mediante la introducción de una solución robótica móvil de vanguardia. Aprovechando las capacidades del robot cuadrúpedo, HyQReal, este sistema, equipado con sensores de brazo y visión, ofrece navegación autónoma y poda de vides, lo que reduce la necesidad de mano de obra, debido al apoyo de la IA (Figura 38).

En el corazón de este enfoque se encuentra un sistema que permite que el robot navegue por los viñedos, identifique las vides con una precisión sin igual y se acerque a ellas para podarlas con precisión.

Este trabajo se basa en un método de navegación basado en visión artificial para robots cuadrúpedos en viñedos, lo que abre nuevas posibilidades para la automatización selectiva de tareas. La arquitectura del sistema funciona bien en condiciones climáticas ideales, generando y llegando a puntos de referencia precisos que maximizan el espacio de trabajo y del brazo robótico adjunto.

La clasificación y el transporte poscosecha de la fruta en el viñedo incluyen la clasificación de los productos defectuosos, su clasificación en categorías según el tamaño

y la calidad, así como su distribución en contenedores y el transporte a las estaciones de recolección en el campo. Los avances en IA pueden acelerar la clasificación y el transporte con alta precisión y robustez para reducir significativamente las pérdidas poscosecha al emplear tecnología para mapear diferentes lotes del viñedo donde operarán los robots cuadrúpedos (Ferreira et al., 2022).




Figura 38. La robótica, de mano con la inteligencia artificial ya ha desarrollado un robot cuadrúpedo que está equipado con sensores de brazo y visión, ofrece navegación autónoma y poda de vides en invierno, lo que reduce la necesidad de intervención humana, debido al apoyo de la IA. (Tomado de: <https://www.ft.com/content/52fcff0e-53db-11ea-8841-482eed0038b1>).

El reporte de Zhou et al. (2023) hace un análisis crítico e identifica desafíos y oportunidades de las aplicaciones de la IA para clasificar y transportar fruta de la huerta. Se investigaron sensores y técnicas para la adquisición de datos que ilustraran las tareas que los modelos de IA deben abordar para la clasificación y el transporte en la granja. También se presentan las ventajas y limitaciones de usar la IA y se proporciona un análisis para identificar futuras direcciones de la investigación. Los autores concluyen que la IA allanará el camino para futuros estudios sobre los sistemas automatizados para la clasificación y el transporte de frutas en las huertas.

La agricultura de precisión es un tema clave en la robótica. La incursión de los robots en la viticultura se ha hecho realidad en los últimos años, ya que están ayudando en tareas sencillas que sustituyen mano de obra y también mediante imágenes hiperespectrales y RGB determinan la presencia de plagas (Botta et al., 2022).

Ahora la robótica no solo se utiliza para el seguimiento del manejo agronómico de los cultivos como, por ejemplo, el uso de robots aéreos para el control del crecimiento. Cada vez los robots tienen una función clave en la vida diaria de los agricultores e industriales

de los alimentos. Las tareas pesadas en el campo como la poda, la siembra o incluso la cosecha precisa son los temas principales de la robótica agrícola.

INTELIGENCIA ARTIFICIAL EN HUERTOS DE MANZANA

Debido a la escasez de mano de obra y al aumento de los costos laborales para la industria de la manzana, existe una necesidad urgente de desarrollar sistemas robóticos para cosechar manzanas de manera eficiente y autónoma, las cuales se clasifican luego con un brazo robótico (Figura 39). En el trabajo de Zhang et al. (2022) se presenta una descripción de un sistema y el diseño de un algoritmo del prototipo de cosechadora robótica de manzanas que recientemente fue desarrollada por estos investigadores.



Figura 39. En muchos países desarrollados se está teniendo la peor época relacionada con la carencia de mano de obra para trabajos de campo no bien remunerados, ahí es donde la inteligencia artificial aplicada a la robótica ayuda mucho en las labores de una huerta de frutales (Tomado de: <https://newatlas.com/robotics/apple-harvesting-robot-fresh-seven-seconds/>).

Ese sistema robótico está habilitado por varios módulos centrales, incluida la percepción visual y el control. Se apoya en múltiples vistas basadas en el aprendizaje profundo y en la huerta logró una recolección promedio de 3.6 segundos por manzana. Esta es una mejora significativa con respecto a otros robots de recolección de manzanas con recolección en el rango de 7 a 10 segundos por manzana. Por lo tanto, este robot muestra un potencial prometedor para un mayor desarrollo de la tecnología de recolección de manzanas eficiente y automatizada.

En el estudio realizado por González et al. (2023) se analizaron variables agroclimáticas en diferentes ventanas de tiempo utilizando técnicas de IA para estimar la extensión del ciclo de crecimiento de la fruta y la fecha de inicio de la cosecha de manzanas

‘Gala’ (*Malus domestica*). Se recolectaron datos meteorológicos y fenológicos de cinco huertas en Chile Central, entre los años 2004 y 2019.

Los atributos derivados de la temperatura del aire durante los primeros días de la fructificación mostraron una alta relación con la fecha de inicio de la cosecha: El número de horas por debajo de 18°C desde la plena floración hasta los 35 d después ($R = 0.9$) y el crecimiento grados hora acumulados desde plena floración hasta los 45 d ($R = -0.84$). Con estos atributos se desarrollaron diferentes modelos de regresión lineal simple y múltiple fueron los más precisos para explicar la duración del período de crecimiento total de la fruta hasta la cosecha.

La ventana de tiempo de 35 días después de la plena floración fue la más efectiva, con un $R^2 = 0.82$, para estimar la fecha de inicio de la cosecha de las manzanas ‘Gala’. Estos resultados contribuyen a la demanda de los productores de manzanas de programar la cosecha y el procesamiento de la fruta, especialmente en un escenario de cambio climático.

Muchos factores están afectando la dinámica de crecimiento de la fruta en los árboles frutales. El déficit de presión de vapor (VPD), la medida del poder de secado del aire que integra datos de temperatura y humedad del aire, es uno de los factores cruciales que afectan este proceso.

El estudio de Armağan et al. (2023) en un huerto de manzanas en el sureste de Francia, con una red de sensores inalámbricos registró el diámetro de la fruta y los valores de VPD. Se creó un modelo de regresión utilizando algoritmos de predicción y aprendizaje de avance. Con el modelo obtenido, se calculan las relaciones entre VPD y el crecimiento de la fruta. A modo de ejemplo, cuando mantenemos constantes las condiciones de humedad y aumentamos la temperatura 2°C en el modelo, el diámetro del fruto disminuye 0.18 %.

La sarna o roña de la manzana es una enfermedad fúngica causada por *Venturia inaequalis*. La enfermedad es de particular preocupación, ya que causa un daño significativo a la fruta y las hojas, lo que lleva a la pérdida en el valor de la fruta y el rendimiento. El artículo de Rouš et al. (2023) examinó la capacidad del aprendizaje profundo y las imágenes hiperespectrales para identificar con precisión mediante IA una infección en los manzanos.

Las imágenes fueron entrenadas y evaluadas con una versión modificada de la red YOLOv5. A pesar de los resultados prometedores del aprendizaje profundo utilizando imágenes RGB, la detección de la sarna o roña en los manzanos utilizando imágenes multiespectrales resultó ser una tarea difícil. El entorno de alta luminosidad del campo abierto dificultaba la recopilación de un espectro equilibrado de la cámara multiespectral, ya que el canal infrarrojo y los canales visibles debían equilibrarse constantemente para que

no se sobreexpusieran en las imágenes.

Expertos en robótica del Centro de Tecnología de Manufactura (MTC) de Inglaterra han desarrollado un robot autónomo con potencial para revolucionar la fruticultura. Combinando robótica, automatización, inteligencia artificial y sistemas de visión avanzados, el robot puede inspeccionar cultivos en busca de madurez y calidad y detectar enfermedades y plagas.

Basado en Spot, el perro robótico (Figura 40), un robot móvil desarrollado por Boston Dynamics, denominado el proyecto RoboCrop puede reducir drásticamente la cantidad de productos químicos y pesticidas utilizados en la agricultura, además de aumentar el rendimiento de los cultivos y mejorar la calidad de los productos, al mismo tiempo que reduce los costos en huertos de frutales y eso se puede extrapolar a cualquier cultivo.



Figura 40. La computadora y la cámara a bordo del RoboCrop se combinan con un sistema de procesamiento de imágenes de inspección de manzanos especialmente diseñado para escanear frutos en busca de calidad, madurez, plagas y enfermedades. El proceso significa que los productos químicos solo se aplican donde y cuando sea necesario, evitando la necesidad de rociar campos y huertos enteros. (Tomado de: <https://www.pesmedia.com/spot-the-robotic-dog-helps-out-down-on-the-farm>).

Por otro lado, con el fin de garantizar la cobertura del área del dosel con la configuración mecánica más compacta posible, el estudio de Xiong et al. (2022) sobre un robot cosechador de manzana propone un método con optimización de configuración dual para el robot cosechador de manzanas en China.

Esos autores diseñaron un manipulador dual de coordenadas cartesianas con dos grupos de operaciones sincrónicas verticales y un rango de movimiento de tres grados

basado en las características de la distribución espacial de las manzanas bajo un dosel típico de plantación cerrada con árboles en porta injertos enanizantes. El manejo de la carga de frutos de un cultivo es la estrategia agronómica más importante pero muy difícil que determina la rentabilidad anual de los huertos de manzanos. La polinización y el raleo son los dos aspectos que afectan en gran medida el manejo eficaz de la carga de frutas.

La polinización tradicional de la flor del manzano depende en gran medida del alquiler de colmenas de abejas, que están disminuyendo rápidamente. Las condiciones ambientales también interfieren con el proceso de polinización natural, lo que genera una gran incertidumbre para lograr una polinización óptima (Iwanami et al., 2023).

Después de la polinización, aplicar la cantidad adecuada de raleo sigue siendo un

El raleo excesivo también conlleva riesgos económicos, ya que se reducirán el rendimiento y el valor de la cosecha en el año de la aplicación. Por lo tanto, en el estudio de Mu y He (2022), se desarrolló un sistema robótico para el manejo de carga del cultivo de manzanas similar al de la Figura 41, para lograr un alto rendimiento y calidad de los cultivos de frutas, lo que resulta en un beneficio económico sustancial para la industria de árboles frutales.




Figura 41. Al igual que muchas industrias en todo el mundo, la cosecha de frutas se ha visto muy afectada por la falta de mano de obra en el mercado laboral. Debido a eso una solución parcial es un robot que puede cosechar manzanas. (Tomado de: <https://www.theguardian.com/us-news/2022/may/28/robot-agriculture-farming-artificial-intelligence>).

INTELIGENCIA ARTIFICIAL EN HUERTOS DE PALMAS

En esta parte nos enfocaremos al uso de la IA en tres tipos de palmas: las

productoras de aceite, palmas cocoteras y datileras. Las palmas son muy importantes para las economías de muchos países, particularmente en el norte de África y el Medio Oriente, donde es considerada como “la princesa de los frutales sustentables” (El-Mously, 1998).

El monitoreo en términos de detección y conteo de palmeras proporciona información útil para muchas partes interesadas; ayuda en la estimación del rendimiento para garantizar una mejor calidad de los cultivos y prevenir plagas, enfermedades, un mejor riego y otras amenazas potenciales. A pesar de su importancia, esta información sigue siendo difícil de obtener (Chen y Liao, 2020).

En el estudio de Hajjaji et al. (2022) se revelan patrones, relaciones, redes y tendencias en la aplicación de la IA en la detección de palmeras durante la última década. A pesar de los buenos resultados obtenidos en la mayoría de los estudios, el manejo eficaz y eficiente de las plantaciones de palma a gran escala sigue siendo un desafío.

Además, los países cuya economía está fuertemente relacionada con los servicios inteligentes en palmas, especialmente en el norte de África, deberían prestar más atención a este tipo de estudios, ya que los resultados pueden beneficiar a los productores, investigadores y otras partes interesadas.

En relación con las palmas datileras el picudo rojo de las palmeras (RPW) es la plaga más dañina. Debido a su rápida propagación y efecto devastador, la ONU y la FAO han declarado que el RPW es una amenaza de categoría 1 para las industrias de la palma en los Estados Unidos. El reporte de Sheikh et al. (2022) menciona que esta plaga se detectó por primera vez en el sur de Asia y luego se encontró en huertas de palmeras en otros continentes.

En 2011, se descubrió RPW en las palmeras de San Diego, California y se cree que migró desde Tijuana, México. El gorgojo también se detecta en Yuma, Arizona y Álamo, Texas. Una mayor propagación de esta virulenta plaga puede afectar a la industria datilera, que aporta alrededor de \$89 millones al año a las economías de California y Arizona.

También están en riesgo los dátiles, el coco, el aceite africano, y las palmeras decorativas valoradas en más de 280 millones de dólares al año. Por lo tanto, la detección temprana de la infestación de RPW mediante IA es esencial para evitar graves consecuencias económicas y riesgos para la seguridad.

Un fenómeno mundial después de la pandemia del Covid-19 es que, a medida que la población prefiere cada vez más trabajos tecnológicos, ahora hay escasez de mano de obra para cosechar cocos en la India. Es por eso que los científicos han construido un robot que trepa palmas y cosecha cocos (Figura 42), que tal vez algún día podría sustituir a los humanos para la cosecha. Esto es un gran avance porque la carencia de cosechadores que

trepen los troncos de las palmeras cada vez se agudiza más.



Figura 42. La cosecha de palmas cocoteras se está modernizando al usar la inteligencia artificial para desarrollar robots que primero se sujetan al tronco, para luego escalar, y una vez que ha llegado a los cocos, su brazo se extiende y usando una hoja de sierra circular en el extremo del brazo procede a cortar esa base, permitiendo que los cocos caigan al suelo. (Tomado de: <https://robertopizzahouse.com/order-now/coconut-harvesting-robot-k.html>).

El área de plantaciones con palma aceitera en Indonesia aumentó de 14 millones de ha en 2017 a 15 millones de ha en 2021. Esa vasta tierra requiere el apoyo de técnicas de manejo eficaces y eficientes para mantener una productividad sostenible de aceite. Sastrohartono et al. (2022), consideran que las tecnologías informáticas de alto rendimiento, internet de las cosas (IoT), big data, inteligencia artificial, modelado espacial y drones son la respuesta a estas necesidades.

La IA se viene aplicando en los drones como una tecnología que ayuda a los múltiples procesos de la agricultura, a captar información importante y a evaluar las condiciones de los terrenos monitoreados, gracias a sus grandes ventajas para sobrevolar los campos y los cultivos (González et al., 2017). Ahora no es completamente necesario recorrer todo el cultivo personalmente para detectar los problemas que sufre este, ya que con los drones el procedimiento de evaluar los cultivos se puede hacer de forma virtual y con una gran precisión.

Actualmente aplicando tecnologías de IA donde se incorporan en drones cámaras con alta definición e información georreferenciada para su ubicación exacta, se puede ubicar cada palma en particular, o bien grupos de palmas con coloraciones similares (Figura 43) que reflejan potenciales problemas de plagas, estrés hídrico, etc.

Lo más importante es poder determinar de forma prematura y eficiente las

enfermedades, las plagas, la maleza y los posibles efectos futuros de daños climáticos como las heladas o sequías. La eficiencia, tanto ambiental como económica, incrementada por el uso de drones de reconocimiento o fumigación ayudan mucho en los procesos de siembra, aplicación del riego, fertilización y fumigación de huertos de palmas aceiteras.



Figura 43. Se ha señalado que el uso de drones hace el trabajo de 500 operarios, lo que está transformando el manejo agronómico de las huertas con palmas de aceite en Asia (Tomado de: <https://www.bloomberg.com/news/articles/2019-11-18/drones-that-do-the-work-of-500-farmers-are-transforming-palm-oil#xj4y7vzkg>).

El término Fresh Fruit Bunch (FFB) es el componente principal en la producción de aceite de palma. Cosechar FFB de árboles de palma de aceite en su etapa máxima de madurez es crucial para maximizar la tasa de extracción de aceite y la calidad.

En las prácticas de cosecha actuales, la clasificación errónea de los frutos maduros (RFF) puede ocurrir debido a un error humano, lo que resulta en la pérdida de aceite (Chew et al., 2021). Los agregados de residuos de palma aceitera pueden producir grandes volúmenes de restos. Por ejemplo, las estimaciones revelan una producción anual de 4 millones de toneladas de este agregado en Malasia, mientras que solo una fracción se utiliza para producir combustible y carbón activado.

En el artículo de Mubin et al. (2019), se usó un enfoque de aprendizaje profundo para predecir y contar palmas aceiteras en imágenes satelitales. Las detecciones anteriores de palmas se enfocaban en detectar árboles que no tienen copas superpuestas. Esta investigación utilizó dos redes neuronales de convolución (CNN) diferentes para detectar

palmas jóvenes y maduras por separado y utiliza GIS para el procesamiento de datos y el almacenamiento de resultados. La arquitectura inicial desarrollada se basa en una red CNN llamada LeNet. El proceso de entrenamiento reduce la pérdida utilizando un algoritmo de gradiente adaptativo con un mini lote de tamaño 20 para todos los conjuntos utilizados.

Estos resultados recientes de diversos investigadores de todo el mundo ponen de relevancia la importancia de la IA para apoyar el manejo agronómico de frutales de una manera sustentable y en armonía con los agroecosistemas, tanto de árboles frutales como de cultivos de grano, etc.

El cultivo de frutales tiene acción muy importante en la solución de problemas de suministro de alimentos en muchos países. Sin embargo, el rendimiento y la calidad de las frutas pueden verse afectados por diversas enfermedades y, por lo tanto, la identificación oportuna y precisa de las condiciones de la enfermedad es particularmente importante.

Actualmente, el uso de tecnología de reconocimiento de imágenes y detección de objetos para diagnosticar enfermedades de los árboles frutales se ha convertido en un punto crítico de investigación. Las redes neuronales convolucionales eliminan el preprocesamiento de la selección manual de funciones y tienen un alto rendimiento de reconocimiento. Sin embargo, no es fácil de entrenar debido al riesgo de desaparición del gradiente (Kabilesh et al., 2023).

Por lo tanto, Lai et al. (2022) proponen un sistema de detección de frutos maduros basado en visión como el primer paso en un sistema robótico de recolección de RFF. En este trabajo, la entrada de la cámara en vivo alimenta a un modelo de red neuronal convolucional (CNN) conocido como YOLOv4 para detectar la presencia de frutos maduros en las palmeras de aceite en tiempo real. Una vez que se detecta un FFB maduro en la palma, se transmite una señal al mecanismo robótico de recolección de futos de palma aceitera (Figura 44).



Figura 44. La cosecha de frutos maduros listos para la extracción de su aceite con el apoyo de la inteligencia artificial y drones ya se viene aplicando en huertos de palma aceitera. Esto permite que la poca mano de obra disponible sea usada en otras labores de campo (Tomado de: <https://www.just-food.com/news/indonesia-palm-oil-export-ban-may-be-partial/>).

INTELIGENCIA ARTIFICIAL EN HUERTOS DE CÍTRICOS

Los modelos de aprendizaje profundo (AP) han presentado resultados prometedores cuando se aplican a la agricultura de precisión 4.0. Entre otras aplicaciones, estos modelos se pueden utilizar en la detección de enfermedades y el conteo de frutas en huertos de cítricos (da Silva et al., 2023). Los modelos de aprendizaje profundo suelen tener muchas capas en la arquitectura y millones de parámetros.

Este aspecto dificulta el uso de AP en dispositivos móviles, ya que requieren una gran cantidad de potencia de procesamiento para la inferencia. Se destaca que el sistema propuesto por esos autores tiene una baja demanda computacional, lo que permite el uso de modelos de baja huella para tareas de detección, clasificación y para detectar los frutos en los árboles.

La detección de cítricos verdes en huertos proporciona un apoyo para las cadenas de manejo de la producción, como el raleo de frutos, la prevención de quemaduras solares y la estimación del rendimiento. En el artículo de Lyu et al. (2022) se propuso un modelo de detección de objetos YOLOv5-CS (Citrus Sort) para realizar la detección de frutos y el conteo preciso de cítricos verdes en el entorno natural.

Primero se emplearon códigos de rotación de imágenes para mejorar la capacidad de generalización del modelo. En 2o lugar, en la columna vertebral, se reemplazó una

capa convolucional por un módulo de atención de bloque convolucional, y se incrustó una capa de detección para mejorar la precisión de detección del cítrico pequeño. En 3er lugar, tanto la función de pérdida CloU (Intersección completa sobre unión) como el algoritmo de coseno se utilizan para obtener un mejor del modelo. Finalmente, el modelo se migra y se implementa en el sistema perimetral de inteligencia artificial.

La cosecha de cítricos es una tarea intensiva muy demandante de mano de obra y tiempo. A medida que la población mundial continúa envejeciendo, los costos laborales aumentan drásticamente. Por lo tanto, el robot cosechador de cítricos ha atraído una atención considerable de las comunidades empresarial y académica (Figura 45). Sin embargo, la cosecha robótica en huertos de cítricos naturales y no estructurados sigue siendo un desafío.



Figura 45. Cosecha de cítricos en una huerta de Japón por un equipo que emplea inteligencia artificial para seleccionar y cortar las frutas maduras en 11 segundos, las cuales luego son colectadas en cajas (Tomado de: <https://www.futurefarming.com/tech-in-focus/automatic-fruit-harvesting-robot-developed-in-japan/>).

El estudio de Yin et al. (2023) tuvo como objetivo abordar algunos desafíos que se enfrentan en la comercialización de robots para cosechar cítricos. Presentaron una solución totalmente integrada, autónoma e innovadora para robots de cosecha de cítricos para superar las dificultades de cosecha derivadas de las características de crecimiento natural de los árboles.

Se usa un algoritmo combinado de localización y mapeo simultáneo basado en múltiples sensores para realizar una localización y navegación de alta precisión para el robot en el campo. Las evaluaciones mostraron que el robot puede cosechar cítricos de

forma continua con una tasa de éxito de 87.2% y un tiempo de recolección de 10.9 s/fruta. Estos datos proporcionan una base sólida para la futura comercialización de robots para la cosecha de cítricos.

La predicción del rendimiento de cítricos brinda información crítica antes de la cosecha a los productores y la industria para predecir los recursos necesarios para los trabajadores, el almacenamiento y el transporte de la fruta cosechada.

Vijayakumar et al. (2023) usaron tres modelos basados en aprendizaje automático (ML) para la predicción del rendimiento de cítricos a nivel de árbol: (i) el modelo 1 utilizó imágenes de UAV; (ii) el modelo 2 utilizó imágenes de vehículos aéreos no tripulados y detección y conteo de frutas en el suelo a partir de imágenes tomadas desde un lado del árbol; y (iii) Model-3 utilizó imágenes de UAV y detección y conteo de frutas a partir de imágenes tomadas desde dos lados del árbol.

Se utilizaron cuatro algoritmos de ML: regresión de aumento de gradiente (GBR), regresión de bosque aleatorio (RFR), regresión lineal (LR) y regresión de mínimos cuadrados parciales (PLSR) para generar los modelos. Los resultados señalan que el Modelo 2 (MAPE de 23.45%) se desempeñó de manera similar al Modelo 3 (MAPE de 25.72%) y significativamente mejor que el Modelo 1 (MAPE de 35.59%). Concluyeron que el Modelo 2 fue seleccionado como el mejor debido a su bajo valor de MAPE en la predicción del rendimiento a nivel de árbol y la simplicidad de la recopilación de datos en comparación con el Modelo 3.

Lograr una detección rápida y precisa de las frutas de los árboles de cítricos en entornos naturales es esencial para muchas aplicaciones de agricultura de precisión cuando se usan robots de cosecha y se estima el rendimiento). En el estudio de Chen et al. (2022) se propuso un método de reconocimiento de cítricos en tiempo real mediante la mejora del último detector YOLOv4 (You Only Look Once version 4) para usar en entornos de huertos.

Los autores usaron los algoritmos Canopy y el K-Means++ para seleccionar el número y el tamaño de los fotogramas correspondientes al conjunto de datos de la imagen. Luego, se agregó un módulo de mecanismo frente a la capa de salida de cada característica de diferentes escalas, y se añade un módulo de convolución separable en profundidad antes del muestreo ascendente del cuello de la red para detectar mejor las mandarinas o clementinas. Finalmente, la red se poda utilizando el algoritmo de red neuronal basada en el control científico (SCOP), y los parámetros del modelo podado se ajustan para restaurar precisión de reconocimiento.

El objetivo general del estudio de Moussaid et al. (2022) fue definir un sistema inteligente para predecir el rendimiento de los cítricos antes del período de cosecha. Este

sistema utiliza un algoritmo de aprendizaje automático entrenado en datos de campo históricos combinados con información espectral extraída de imágenes de satélite. Para ello, utilizaron 5 años de datos históricos para un huerto marroquí compuesto por 50 parcelas.

Se evaluaron varios algoritmos de aprendizaje automático con la optimización necesaria de parámetros, mientras que el algoritmo de seguimiento automático ortonormal dió buenas puntuaciones de predicción de 0.2489 (MAE: error absoluto medio) y 0.0843 (MSE: error cuadrático medio). Concluyen los autores diciendo que el enfoque seguido en este estudio muestra un excelente potencial para la predicción del rendimiento de frutos.

El color de la cáscara de los cítricos es un buen indicador del desarrollo de la fruta y para los métodos que monitorean y predicen la madurez. El trabajo de Bao et al. (2023) presenta el flujo de trabajo completo para predecir y visualizar la transformación del color de los cítricos en el huerto con alta precisión. Se observaron 107 ejemplares de naranjas Navel durante el período de transformación de la coloración, lo que produce un conjunto de datos con 7535 imágenes.

Desarrollaron un marco que integra la prominencia visual en el aprendizaje profundo, y consiste en una red de segmentación, una red generativa guiada por máscara y una red de pérdida con funciones de pérdida diseñadas manualmente. Además, la fusión de las características de la imagen y la información temporal permite que un solo modelo prediga el color de la corteza en diferentes intervalos de tiempo, reduciendo así el número de parámetros del modelo.

Para facilitar las aplicaciones en el mundo real, el modelo tiene un sistema basado en Android para dispositivos móviles. Los métodos se pueden expandir fácilmente a otros cultivos frutales con un período de transformación del color. El conjunto de datos y el código fuente están disponibles públicamente en GitHub.

INTELIGENCIA ARTIFICIAL EN HUERTOS DE BANANOS

Los bananos o plátanos son las frutas más comercializadas del mundo. Se han desarrollado varios modelos analíticos que utilizan inteligencia artificial para resolver los desafíos que enfrenta la cadena de suministro del banano. El estudio de Almeyda e Ipanaqué, (2022) revisa el escenario actual de la investigación científica que involucra la IA en las etapas de la cadena de suministro que son: precosecha, cosecha, poscosecha, procesamiento y venta al por menor.

Este documento revela 11 áreas de aplicación de IA para bananos, como madurez, enfermedades de las hojas, clasificación de calidad, tipo de cultivo, rendimiento y control

del suelo. Además, resume la funcionalidad principal de los algoritmos de aprendizaje como: ANN, CNN, SVM y K-NN. Esta revisión ayudará a los investigadores a comprender las aplicaciones de la IA en el sector bananero y analizar la brecha de conocimiento para futuros estudios.

Uno es el modelo de detección YOLO-Banana, que analiza las características del fruto y la estructura de la red para eliminar las capas de red menos importantes; el otro es el modelo de detección YOLO-Banana-I4 que, al agregar una capa de cabeza YOLO a la estructura de la red y explora el impacto de una estructura de predicción de cuatro escalas en la red podada.

La detección en tiempo real de racimos y tallos de banano en plantaciones bananeras es una tecnología clave en la aplicación de robots agrícolas. Las complejas condiciones del huerto hacen que la detección precisa sea una tarea difícil. El reporte de Fu et al. (2022a) compara dos modelos de detección de redes neuronales YOLOv4 en un huerto de plátanos (Figura 46).




Figura 46. Imágenes de un campo bananero ilustrando el resultado de la detección de la estrecha interferencia entre el pecíolo y el tallo: (a) YOLOv4; (b) YOLO-Plátano; (c) YOLO-Plátano-I4 (Tomado de Fu et al., 2022a).

Los resultados muestran que YOLO-Banana y YOLO-Banana-I4 podrían reducir el peso de la red y acortar el tiempo de detección en comparación con YOLOv4. Además, el modelo de detección YOLO-Banana tiene el mejor rendimiento, con una buena precisión de detección de racimos y tallos de plátano en el entorno natural. Cuando el tamaño de los racimos y el tallo del racimo de banano era grande, los casos detectados falsamente eran raros.

Con la aplicación generalizada de la tecnología de visión artificial en la agricultura, el manejo inteligente de los huertos de banano es urgente. La detección precisa de racimos y tallos de banano es una condición previa para la estimación del rendimiento del huerto y la cosecha automática. En un entorno de huerto de banano complejo, los racimos y tallos tienen un color similar al de las hojas, y los tallos de banano tienen una textura similar al pecíolo, lo que dificulta la detección de racimos y tallos de banano en huertos de banano

(Tang et al., 2020).

En este sentido el estudio de Fu et al. (2022b) propone un método de detección multiclase preciso y rápido para racimos y tallos de banano. Se utilizó una cámara RGB normal para recopilar imágenes y se usó la red YOLOv4 para detectar los racimos y tallos de banano. El modelo de detección de racimos y tallos de banano mostró una excelente confiabilidad en diferentes escenarios de iluminación.

La detección de racimo y tallo de banano fue de 99.55% y 87.82% respectivamente. El tiempo medio de ejecución fue de 44.96 ms. Los resultados muestran que la detección rápida en tiempo real de racimos y tallos de banano en el entorno natural es útil para el manejo inteligente de los huertos de banano.

Muchos aspectos de la industria agrícola, como la siembra y cosecha de cultivos de campo y la aplicación de productos químicos en cultivos de frutales, han estado empleando soluciones de mecanización y automatización durante décadas. Sin embargo, en las operaciones poscosecha de banano generalmente se realiza manualmente (Guo et al., 2022).

Las bananas se cultivan principalmente en países en desarrollo ubicados en regiones tropicales y subtropicales, donde el desarrollo de soluciones de automatización mediante IA y la mecanización agrícola está progresando con relativa lentitud. Además, los huertos de banano a gran escala se distribuyen principalmente en áreas montañosas, aunque también hay algunas plantaciones de banano a pequeña escala en áreas planas (Figura 47).

Los plátanos son uno de los cultivos frutales más cultivados en Malasia, pero la producción ha disminuido en los últimos años. A través de visitas de sitio y entrevistas con 74 pequeños productores, el estudio de Jalaluddin y Othman (2022) determinó la situación actual de la industria bananera a pequeña escala, los desafíos que enfrenta el cultivo de banano y el uso de biotecnologías para abordar los retos.

Los bananeros mencionaron que sus problemas más importantes son: el aumento de los costos de producción, plagas, enfermedades y las incertidumbres, como los principales desafíos para la supervivencia de sus plantaciones. Mientras han estado utilizando técnicas agrícolas, incluidas la biotecnología para mejorar el rendimiento, los agricultores percibieron las tecnologías actuales como inadecuadas para mitigar los frecuentes brotes de enfermedades, por lo que la IA podría ayudarlos.



Figura 47. Huertos de banano y sus patrones de crecimiento. (a) Aspecto de un huerto de banano ubicado en una zona montañosa con colinas. (b) Muestra la vista interior de una plantación de banano en zonas planas o llanuras (Tomado de: Guo et al., 2022).

Recientemente Wu et al. (2022) han señalado que los robots primero deben detectar la cantidad de racimos de banano al hacer juicios sobre la eliminación de yemas estériles y estimar el peso para la cosecha en el campo. Los racimos de banano tienen una forma compleja, están dispuestos en una curva helicoidal no lineal a lo largo del tallo y tienen diferentes estados de crecimiento en diferentes períodos, con racimos muy espaciados en el período temprano y densamente dispuestos en el período de cosecha.

Debido a lo antes mencionado la IA empleando el aprendizaje profundo o los algoritmos clásicos de procesamiento de imágenes pueden detectar y contar racimos en ambos períodos. Por lo tanto, estos algoritmos se combinaron para calcular el número de racimos en los dos períodos.

Para contar los racimos basado en el aprendizaje profundo para identificar el racimo de la fruta del banano, se empleó el algoritmo de detección de bordes para extraer los puntos del centroide de los dedos de la fruta, y el algoritmo de agrupamiento se usó para determinar la cantidad óptima de racimos. Este estudio concluye que sus resultados son una buena referencia para la aplicación del sistema de visión estéreo en un complejo huerto de banano.

INTELIGENCIA ARTIFICIAL EN HUERTOS DE MANGOS

El sistema de riego inteligente basado en IoT para huertos de mango se enfoca en ahorrar agua y obtener un mejor rendimiento mediante el control de la cantidad de agua por aplicar, que se basa en datos meteorológicos de los satélites, la humedad del suelo y

también de la planta. Además de eso, el sistema propuesto por Chandu y Shukla (2023) es robusto e inteligente ya que puede manejar las situaciones de sequía y abundancia de agua (inundación).

Los autores usan el microcontrolador que procesa los datos disponibles de varias fuentes y devuelve la cantidad de agua necesaria para el riego de los árboles de mango. Además, se puede acceder a toda la interfaz a través de una aplicación. Los datos meteorológicos están disponibles en Internet y se bajan mediante sensores remotos. El sistema utiliza los valores de referencia ya disponibles para decidir el valor apropiado para regar los árboles, lo que ayudará aún más a obtener un mejor rendimiento de mangos. La detección de frutas en los huertos es crucial para aplicaciones agrícolas como la estimación automática y el mapeo del rendimiento.

La IA y los enfoques de última generación para esta tarea se basan en características hechas a mano y, por lo tanto, están sujetos a variaciones en un entorno de huerto real. Sin embargo, los métodos actuales de detección de frutos de una etapa basados en el aprendizaje profundo, como YOLO, brindan una excelente precisión a costa de una mayor complejidad computacional. Por lo tanto, el trabajo de Chandana et al. (2023) presenta un modelo YOLOv5s mejorado, rápido y compacto denominado MangoYOLO5 para detectar mangos en huertos de mango proporcionados por el conjunto de datos MangoNet-Semantic. El MangoYOLO5 propuesto ha adoptado algunas mejoras sobre YOLOv5s.

Las estimaciones anticipadas de la posible cosecha automatizada (Figura 48) con la ayuda de IA requieren información sobre el tamaño y el número de frutos. La tarea de medir el tamaño se ha automatizado en la empacadora, pasando de los métodos mecánicos a la visión artificial en las últimas tres décadas. Este cambio con la IA está ocurriendo ahora para la evaluación del tamaño de la fruta de los árboles en el huerto.

La revisión de Neupane et al. (2023) se enfoca en: (i) las relaciones alométricas entre el peso de la fruta y las dimensiones lineales; (ii) medición de dimensiones lineales de frutos con herramientas tradicionales; (iii) medición de dimensiones con visión artificial; (iv) estrategias de muestreo; y (v) predicción anticipada del tamaño de la fruta (al momento de la cosecha). Se concluye que la capacidad disponible para el calibrado de frutas en el huerto y los nuevos desarrollos mediante visión artificial, simplificarán mucho la predicción del rendimiento de magos.



Figura 48. Con la ayuda de técnicas de inteligencia artificial ya se ha desarrollado en Australia una máquina cosechadora robótica de mango, la cual está casi lista para la comercialización en todo el mundo (Tomado de: <https://www.futurefarming.com/crop-solutions/australian-mango-harvester-nearing-commercialisation/>).

Después de varios años de pruebas y la instalación de nuevos mecanismos, sistemas de cámara y pinzas, el investigador principal, el profesor Kerry Walsh de CQUniversity Australia, dice que el desarrollo de la cosechadora está en la recta final para proceder a su comercialización. Señala que, si tienes una fruta a tu alcance ahora, con estas nuevas pinzas del robot, básicamente, siempre la podrás arrancar del árbol; además, donde había ocho personas trabajando alrededor de la cosecha, ahora están agregando brazos mecánicos al proceso, reduciendo mano de obra.

La falta de conjuntos de datos estándar y disponibles públicamente relacionados con la agricultura impide que los profesionales de esta disciplina aprovechen al máximo las poderosas herramientas y técnicas predictivas computacionales mediante la IA. Para mejorar este escenario, se han desarrollado conjuntos de datos estándar, listo para usar y disponible públicamente para hojas de mango.

En el estudio realizado por Ahmed et al. (2023) las imágenes se recopilaron de cuatro huertos de mango de Bangladesh, uno de los principales países productores de mango del mundo. El conjunto de datos contiene 4000 imágenes de 1800 hojas que arrojan siete enfermedades. Aunque el conjunto de datos se desarrolló utilizando hojas de mango de Bangladesh, dado que se trataron enfermedades que son comunes en muchos países, es probable que este conjunto de datos también se pueda aplicar para identificar enfermedades del mango en otros países, lo que aumentará su rendimiento. Se espera

que este conjunto de datos atraiga la atención de los investigadores y profesionales del aprendizaje automático en el campo de la IA agrícola.

La falta de agua cada vez se agrava más por el abatimiento de los acuíferos subterráneos y el calentamiento global. La sequía extrema está afectando a todas las zonas áridas y semiáridas del mundo, causando incendios de bosques y cultivos siniestrados por la falta de agua; por eso es importante apoyarnos con herramientas de IA para hacer un uso más eficiente y racional de este vital líquido.

Debido a esto, Hahn et al. (2022) trabajó en un huerto comercial de mangos con árboles maduros de 25 años y una sección de alta densidad de 10 años se regaron con microaspersores usando 100% ETc y tratamientos de riego deficitario reducido de 75 y 50% ETc. Señalan que después de la cosecha de 2020, el volumen del dosel, el tamaño del mango, el rendimiento de fruta y la eficiencia del uso del agua se analizaron durante 2020 y 2021.

Los autores mencionan que un controlador con un algoritmo difuso optimizó el manejo del huerto y ahorró agua en los árboles sin disminuir el rendimiento ni el tamaño de la fruta. Se encontró que un año después de podar los árboles maduros quitando la rama interna más grande, penetraba más luz en el dosel, lo que aumentó el rendimiento en 60%; la poda en árboles de alta densidad aumentó el rendimiento en 5.37%.

La eficiencia en el uso del agua también aumentó con la poda y su valor se acrecentó cuando el controlador difuso y los tratamientos al 50% ETc se usaron en árboles maduros. Este valor fue 260% mayor que el obtenido en árboles podados sin el controlador.

INTELIGENCIA ARTIFICIAL EN HUERTOS DE AGUACATE

La evaluación rápida de la madurez de la fruta después de la cosecha es importante para reducir las pérdidas poscosecha al clasificar la fruta de acuerdo con la duración hasta que esté lista para el consumo. Sin embargo, ha habido poca investigación sobre la estimación no destructiva de la madurez y la velocidad de maduración de la fruta del aguacate. A diferencia de los métodos anteriores, que clasifican la madurez de la fruta en unas pocas categorías (p. ej., verde y madura) o estiman indirectamente la madurez a partir de su firmeza.

Davur et al. (2023) desarrollaron un método que utiliza imágenes hiperespectrales junto con regresión de aprendizaje profundo para estimar directamente la duración hasta la madurez de Hass fruta de aguacate. Se generaron muestras de entrenamiento, validación y prueba como subimágenes de imágenes de frutas Hass y se usaron para entrenar una red residual espectral-espacial para estimar la duración hasta la madurez y lograron

predicciones de duración hasta la madurez con un error promedio de 1.17 días por fruta en el conjunto de prueba.

Esos resultados muestran el potencial de la IA para combinar imágenes hiperespectrales con aprendizaje profundo para estimar la etapa de madurez de la fruta, lo que podría ayudar a afinar la clasificación y el procesamiento de la fruta en huertos de aguacate.

La compañía Apeel comenzó con la misión de prevenir el desperdicio de alimentos en toda la cadena de suministro con un revestimiento protector de la piel basado en plantas. La misión de Apeel no ha cambiado, pero está evolucionando para impulsar aún más el cambio en el sistema alimentario. La expansión de sus ofertas tecnológicas aumentará el acceso a los conocimientos para crear una cadena de suministro más inteligente que maximice la vida útil, la calidad y la sostenibilidad de las frutas y verduras frescas en el anaquel. La productividad agrícola es crucial para abastecer la demanda actual de alimentos. Sin embargo, producir alimentos requiere afrontar retos tecnológicos para alcanzar el nivel de producción demandado. En este contexto, la tecnología internet de las cosas (IoT) se utiliza para la agricultura de precisión.

La manera en que el consumidor se decide a tomar del anaquel los frutos de aguacate es: Aprieta e inspecciona visualmente desde todos los ángulos. Todos tenemos nuestros métodos para determinar la madurez de un aguacate. Pero la compañía Apeel de tecnología de alimentos con sede en California, ha desarrollado un dispositivo basado en IA (Figura 49) que pretende hacer casi lo imposible: un escáner que puede “mirar detrás de la cáscara” y decirles a los consumidores qué tan maduro está un aguacate, para comprarlo y comerlo en 4 o 5 días después.

El artículo de Moreno-Bernal et al. (2022) propone una plataforma de IoT para recolectar y procesar los nutrientes del suelo y los datos meteorológicos del cultivo de aguacates en México. Los datos se colectaron cada 300 s para el monitoreo de 24 h de los árboles de aguacate. La validación experimental registró 8,832 datos para el monitoreo de nutrientes del suelo y variables climáticas de una huerta de aguacate en el Noreste de Morelos, México. Los resultados muestran que la plataforma IoT puede monitorear de manera efectiva información agrícola en la agricultura inteligente.

La creciente demanda de cultivos básicos ha llevado a una expansión rápida y severa de la frontera agrícola a nivel mundial y ha puesto a las regiones productoras bajo una presión cada vez mayor. Sin embargo, la falta conocimiento sobre los patrones espaciales de la dinámica de la frontera agrícola, sus principales determinantes espaciales y las compensaciones socioecológicas, es lo que dificulta la toma de decisiones hacia

sistemas alimentarios más sostenibles.



Figura 49. Un aparato que funciona como scanner toma lecturas del color de la piel del aguacate, así como la rugosidad de la piel y puede señalar cuando pudiera estar listo el fruto para comerlo (Tomado de: <https://www.foodandwine.com/avocado-scanners-ripeness-a-peel-6754889>).

Ramírez-Mejía et al. (2022) usaron datos de inventario para mapear la dinámica de la producción de aguacate, en Michoacán, México, antes y después de la implementación del Tratado de Libre Comercio de América del Norte (TLCAN).

Este es el primer análisis de la dinámica de la frontera del aguacate y sus determinantes espaciales en una importante región de producción en México, y los resultados brindan puntos de entrada para implementar estrategias gubernamentales para apoyar a los pequeños agricultores, principalmente los de tierras comunales, al tiempo que intentan minimizar el impacto social y los impactos ambientales por la producción de aguacate.

Para la obtención de datos sobre los recuentos semanales de trampas de plagas obtenidos por Ibrahim et al. (2022) se utilizaron redes neuronales difusas (FNN) para modelar la dinámica poblacional de *B. dorsalis* y *Ceratitis* spp. Se utilizaron conteos semanales de plagas, lluvia, temperatura promedio, humedad relativa y estados fisiológicos de la planta de aguacate para el modelado predictivo. Los modelos FNN lograron resultados satisfactorios en la predicción de la dinámica de las plagas en los huertos y se demostró que pueden usarse como herramientas predictivas para manejar y controlar las poblaciones de plagas de moscas de la fruta en estas plantaciones.

La demanda de los consumidores de aguacates está muy influenciada por el precio, las promociones, el clima, las vacaciones, el precio de los tomates, el precio de los aguacates orgánicos frente a los convencionales y la estacionalidad. Los factores externos también tienen un gran impacto, como las tendencias alimentarias en constante cambio. Juntos, todos estos factores exigen un pronóstico de demanda altamente adaptable que responda a los cambios en la demanda del consumidor, esto es muy difícil predecir, pero con la ayuda de IA se están diseñando softwares basados en algoritmos y luego una computadora (Figura 50) ayuda en el pronóstico.




Figura 50. La inteligencia artificial está sustentando el desarrollo de nuevas invenciones para determinar la frescura del producto y el momento de madurez de los aguacates (Tomado de: <https://www.afresh.com/resources/forecasting-fresh-why-every-grocery-store-needs-ai>).

A medida que aumenta la demanda de aguacate, la producción de este fruto en Michoacán, la región productora de aguacate más grande de México, se expande a nuevos lugares. Arima et al. (2022) usaron un modelo probit espacial para proyectar la distribución geográfica de la probable expansión futura del aguacate y analizaron esos resultados para determinar (a) las amenazas a tipos de bosques específicos y (b) cómo la distribución del aguacate está cambiando espacialmente bajo los escenarios climáticos actuales y futuros.

Sus resultados indican que la expansión del aguacate en Michoacán está fuertemente limitada por la disponibilidad cada vez menor de suelos Andosol. El modelo predice que el cambio climático alterará la distribución espacial de las plantaciones de aguacate, expandiéndose a bosques en elevaciones más bajas y más altas. Por lo que la producción de aguacate podría conducir al establecimiento de huertos en bosques cada vez más reducidos que albergan una gran diversidad de robles nativos y especies carismáticas, incluida la mariposa monarca.

Los aguacates se han convertido en un elemento básico en las listas de compras de muchos compradores en los últimos años. Con millones de recetas y consejos de salud centrados en el aguacate, no es de extrañar que las ventas se hayan más que duplicado desde 2010. Y para los equipos de producción que dirigen departamentos de productos frescos, mantener fresca en stock esta fruta es crucial y no es tarea fácil.

Por otro lado, la pudrición blanca de la raíz (PBR), causada por el hongo del suelo *Rosellinia necatrix*, es una limitación importante para la producción de aguacate. Los métodos actuales de detección de la PBR se basan en técnicas microbianas y moleculares, y su aplicación a escala de huerto es limitada. En el estudio de Pérez-Bueno et al. (2019), los parámetros fisiológicos generados por las técnicas de imagen se analizaron mediante métodos de aprendizaje automático.

El índice de vegetación de diferencia normalizada (NDVI) y la temperatura del dosel normalizada (temperatura del dosel - temperatura del aire) se analizaron como predictores de enfermedades mediante varios algoritmos. Entre ellos, el análisis de regresión logística (LRA) entrenado con datos NDVI mostró la sensibilidad más alta y la tasa más baja de falsos negativos. Este algoritmo basado en IA podría ser un método rápido y factible para detectar árboles afectados por la PBR en huertos de aguacate.

La producción de aguacate (*Persea americana*) está aumentando en Kenia, con cultivos pequeños y grandes para los mercados nacionales y de exportación. Sin embargo, uno de los principales problemas que limitan su producción es la infestación por plagas de insectos como la mosca *Bactocera dorsalis* y *Ceratitis* spp., que causan pérdidas directas y son indirectamente responsables de las barreras comerciales no arancelarias debido a los estrictos requisitos de exportación.

El diagnóstico de enfermedades basado en síntomas visuales se ve comprometido por la incapacidad de diferenciar entre síntomas similares causados por diferentes factores bióticos y abióticos. En el artículo de Abdulridha, et al. (2019) se presenta y evalúa una técnica automatizada de detección temprana de enfermedades. Esta técnica de teledetección puede detectar una importante enfermedad del aguacate, la enfermedad del marchitamiento del laurel, y diferenciarla de árboles sanos, árboles infectados por la pudrición de la raíz por *Phytophthora* y árboles con deficiencias de Fe y N. La detección de la enfermedad en árboles de aguacate, en etapa temprana, es muy difícil, ya que tiene síntomas similares con otros factores de estrés, como deficiencia de nutrientes, daño por salinidad, pudrición de la raíz por *Phytophthora*, etc.

Estados Unidos importa el 87% de sus aguacates de una sola región mexicana, Michoacán. Los costos ambientales y sociales asociados con la producción de aguacate

son significativos, los consumidores y minoristas en los EE. UU. no pueden distinguirlos claramente, debido a las cadenas de suministro complejas y opacas.

En el estudio de Cho et al. (2021) utilizaron una metodología novedosa denominada, “Tracking Corporations Across Space and Time” (TRACAST), para reconstruir las cadenas de suministro de aguacate entre los minoristas estadounidenses y los productores y exportadores mexicanos. Usando IA y sensores remotos y aprendizaje automático, documentaron cómo las plantaciones de aguacate están asociadas con la deforestación en Michoacán que está afectando la mariposa monarca (*Danaus plexippus*). Estos autores estiman que ~20% de la deforestación total en Michoacán entre 2001 y 2017 está asociada a la expansión de plantaciones de aguacate.

Respecto a la influencia de la IA en nuestra dieta, ya hay un algoritmo que te dice cómo comer para vivir una vida más larga y saludable, incluyendo en ella el aguacate (Figura 51). Como se sabe, un algoritmo es un proceso o un conjunto de reglas seguidas por una computadora que se utiliza para realizar cálculos o resolver problemas, por lo que la dieta de IA se basa completamente en la ciencia.




Figura 51. El aguacate es una fruta oleica muy saludable, la cual es incluida en la dieta de muchas personas, y ya se han desarrollado algoritmos que nos dicen mediante una computadora cuando es el mejor tiempo comer de este fruto maduro (Tomado de: <https://rushcuttershealth.com.au/the-a-i-artificial-intelligence-diet/>).

La pudrición de la raíz por *Phytophthora* (PRR) infecta las raíces de los árboles de aguacate, lo que reduce la absorción de agua y nutrientes, la disminución del dosel, la defoliación y, finalmente, la mortalidad de los árboles. Por lo general, la gravedad de

la enfermedad PRR se evalúa comparando visualmente la salud del dosel de los árboles infectados con un conjunto estandarizado de fotografías y una clasificación de la severidad de distribución (Figura 52) de la enfermedad.

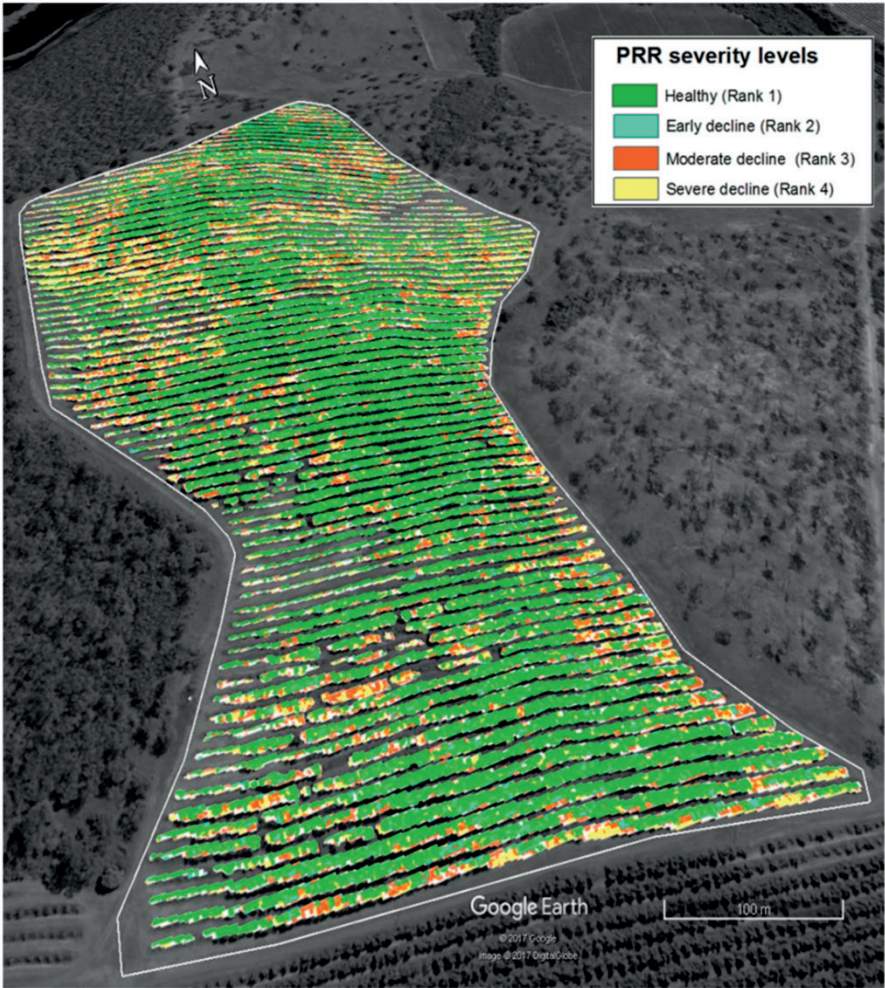


Figura 52. Mapa de distribución de la severidad de pudrición de la raíz por el hongo *Phytophthora* de un huerto de aguacate clasificado según SRVI y superpuesto sobre una capa de elevación (Tomado de: Salgadoe et al., 2018).

El estudio de Kämper et al. (2020), tuvo como objetivo desarrollar métodos de imágenes hiperespectrales para predecir proporciones de seis ácidos grasos, y las concentraciones de 14 nutrientes minerales en frutos de aguacate de la variedad Hass.

Salgadoe et al. (2018) mencionan que, aunque este método visual proporciona indicación de la variabilidad espacial de la enfermedad PRR en los huertos, la precisión y la repetibilidad de la clasificación están influenciadas por la experiencia del evaluador, la visibilidad de las copas de los árboles y el momento de la evaluación.

Muchos parámetros de calidad predichos a partir de imágenes de pulpa también podrían predecirse con IA a partir de imágenes de piel. Las imágenes hiperespectrales representan una herramienta prometedora para reducir las pérdidas poscosecha de la fruta del aguacate al determinar rápidamente la calidad interna de la fruta de forma individual a partir de imágenes de la pulpa o la piel.

CONCLUSIONES

Los datos de rendimiento previo a la cosecha del huerto con información basada en IA son importantes para los fruticultores, ya que se pueden utilizar para evaluar los beneficios económicos, ajustar el modo de manejo, etc. Sin embargo, la operación manual tradicional por estimación de muestreo es una tarea bastante onerosa y requiere mucho tiempo. El enfoque principal del monitoreo automático del rendimiento es mediante el establecimiento de sistemas de predicción integrales de información múltiple o el uso de equipos inteligentes.

La automatización usando IA hace que el mismo proceso sea más consistente y eficiente en el tiempo. La detección de la calidad de la fruta identifica los defectos en las frutas cargando imágenes de frutas en el sistema. Hasta ahora, muchos investigadores han utilizado diferentes técnicas para la detección de calidad basadas en las características de la imagen y han trabajado en la mejora de los parámetros de calidad.

En vista de toda la investigación realizada con IA en árboles frutales se extraen los diversos tipos de características como: forma, tamaño, color o textura, y para la clasificación, se aplican diferentes métodos de aprendizaje automático, como k-vecinos más cercanos, máquina de vector de soporte, red neuronal, etc. Todas estas ventajas de la IA harán que el desarrollo de la fruticultura se potencialice primero en los países desarrollados y después en los demás.

LITERATURA CITADA

- Abdulridha, J., Ehsani, R., Abd-Elrahman, A. y Ampatzidis, Y. (2019). A remote sensing technique for detecting laurel wilt disease in avocado in presence of other biotic and abiotic stresses. *Computers and electronics in agriculture*, 156, 549-557.
- Ahmed, S.I., Ibrahim, M., Nadim, M., Rahman, M.M., Shejunti, M.M., Jabid, T. y Ali, M.S. (2023). MangoLeafBD: A comprehensive image dataset to classify diseased and healthy mango leaves. *Data in Brief*, 47, 108941.
- Almeyda, E. y Ipanaqué, W. (2022). Recent developments of artificial intelligence for banana: Application areas, learning algorithms, and future challenges. *Engenharia Agrícola*, 42.
- Arima, E.Y., Denvir, A., Young, K.R., González-Rodríguez, A. y García-Oliva, F. (2022). Modelling avocado-driven deforestation in Michoacán, Mexico. *Environmental Research Letters*, 17(3), 034015.
- Armağan, H., Atay, E., Crété, X., Lauri, P.E., Ersoy, M. y Oral, O. (2023). Deep learning-based prediction model of fruit growth dynamics in apple. In *Smart Applications with Advanced Machine Learning and Human-Centred Problem Design* (pp. 367-373). Cham: Springer International Publishing.
- Bao, Z., Li, W., Chen, J., Chen, H., John, V., Xiao, C. y Chen, Y. (2023). Predicting and visualizing citrus colour transformation using a deep mask-guided generative network. *Plant Phenomics*.
- Botta, A., Cavallone, P., Baglieri, L., Colucci, G., Tagliavini, L. y Quaglia, G. (2022). A review of robots, perception, and tasks in precision agriculture. *Applied Mechanics*, 3(3), 830-854.
- Chandana, P., Subudhi, P. y Vara Prasad Yerra, R. (2023). MangoYOLO5: A fast and compact YOLOv5 model for mango detection. In *Computer Vision and Machine Intelligence: Proceedings of CVMI 2022* (pp. 719-731). Singapore: Springer Nature Singapore.
- Chandu, E. y Shukla, M.K. (2023, January). IoT-Based smart irrigation system for mango orchard. In *artificial intelligence and machine learning in satellite data processing and services: Proceedings of the International Conference on Small Satellites, ICSS 2022* (pp. 61-69). Singapore: Springer Nature Singapore.
- Chen, Z. Y., Liao, I. Y. (2020). Improved fast r-cnn with fusion of optical and 3d data for robust palm tree detection in high resolution uav images. *International Journal of Machine Learning and Computing*, 10(1), 122-127.
- Chen, W., Lu, S., Liu, B., Chen, M., Li, G. y Qian, T. (2022). CitrusYOLO: a algorithm for citrus detection under orchard environment based on YOLOV4. *Multimedia Tools and Applications*, 81(22), 31363-31389.
- Chew, C.L., Ng, C.Y., Hong, W.O., Wu, T.Y., Lee, Y.Y., Low, L.E. y Chan, E.S. (2021). Improving sustainability of palm oil production by increasing oil extraction rate: A review. *Food and Bioprocess Technology*, 14, 573-586.
- da Silva, J.C., Silva, M.C., Luz, E.J., Delabrida, S. y Oliveira, R.A. (2023). Using mobile edge AI to detect and map diseases in citrus orchards. *Sensors*, 23(4), 2165.

Cho, K., Goldstein, B., Gounaridis, D. y Newell, J.P. (2021). Where does your guacamole come from? Detecting deforestation associated with the export of avocados from Mexico to the United States. *Journal of Environmental Management*, 278, 111482.

Davur, Y.J., Kämper, W., Khoshelham, K., Trueman, S.J. y Bai, S.H. (2023). Estimating the ripeness of hass avocado fruit using deep learning with hyperspectral imaging. *Horticulturae*, 9(5), 599.

El-Mously, H. (1998). The date palm: the princess of sustainable fruits. *Armin, Newsletter*, 23.

Ferreira, J., Moreira, A. P., Silva, M. y Santos, F. (2022, April). A survey on localization, mapping, and trajectory planning for quadruped robots in vineyards. In *2022 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)* (pp. 237-242).

Figueiredo, N., Pádua, L., Cunha, A., Sousa, J.J. y Sousa, A. (2023). Exploratory approach for automatic detection of vine rows in terrace vineyards. *Procedia Computer Science*, 219, 139-144.

Fu, L., Yang, Z., Wu, F., Zou, X., Lin, J., Cao, Y. y Duan, J. (2022a). YOLO-Banana: a lightweight neural network for rapid detection of banana bunches and stalks in the natural environment. *Agronomy*, 12(2), 391.

Fu, L., Wu, F., Zou, X., Jiang, Y., Lin, J., Yang, Z. y Duan, J. (2022b). Fast detection of banana bunches and stalks in the natural environment based on deep learning. *Computers and Electronics in Agriculture*, 194, 106800.

González, A., Amarillo, D., Amarillo, M., Sarmiento, F. (2017) Drones aplicados a la agricultura de precisión. UNAD, *Revista Especializada en Ingeniería*, Vol. 10. ISSN: 1900-6608 V.

González, Y., Sepúlveda, Á. y Yuri, J.A. (2023). Harvest date estimation of ‘Gala’ apples based on environment temperature using artificial intelligence. *Chilean Journal of Agricultural Research*, 83(3), 272-280.

Guo, J., Duan, J., Yang, Z. y Karkee, M. (2022). De-Handling technologies for banana postharvest operations—Updates and Challenges. *Agriculture*, 12(11), 1821.

Hahn, F., Valle, S. y Navarro-Gómez, C. (2022). Pruning and water saving management effects on mango high-density and mature orchards. *Agronomy*, 12(11), 2623.

Hajjaji, Y., Boulila, W. y Farah, I.R. (2022). Leveraging artificial intelligence techniques for smart palm tree detection: A Decade Systematic Review. *Procedia Computer Science*, 207, 2823-2832.

Ibrahim, E.A., Salifu, D., Mwalili, S., Dubois, T., Collins, R. y Tonnang, H.E. (2022). An expert system for insect pest population dynamics prediction. *Computers and Electronics in Agriculture*, 198, 107124.

Iwanami, H., Moriya-Tanaka, Y., Hanada, T., Baba, T. y Sakamoto, D. (2023). Meteorological and tree-management factors related to soluble solids content of apple fruit and crop load management for producing high soluble solids content fruit in high-density planted ‘Fuji’. *Scientia Horticulturae*, 310, 111755.

Jalaluddin, N.S.M. y Othman, R.Y. (2022). Perceptions on the challenges of banana cultivation and bio-based technology use among Malaysian smallholder farmers. *Asian Journal of Agriculture and Development*, 19(2), 25-34.

- Kabilesh, S.K., Mohanapriya, D., Suseendhar, P., Indra, J., Gunasekar, T. y Senthilvel, N. (2023). Research on artificial intelligence based fruit disease identification system (AI-FDIS) with the internet of things (IoT). *Journal of Intelligent & Fuzzy Systems*, (Preprint), 1-16.
- Kalopesa, E., Karyotis, K., Tziolas, N., Tsakiridis, N., Samarinas, N. y Zalidis, G. (2023). Estimation of sugar content in wine grapes via in situ VNIR–SWIR Point spectroscopy using explainable artificial intelligence techniques. *Sensors*, 23(3), 1065.
- Kämper, W., Trueman, S.J., Tahmasbian, I. y Bai, S.H. (2020). Rapid determination of nutrient concentrations in Hass avocado fruit by Vis/NIR hyperspectral imaging of flesh or skin. *Remote Sensing*, 12(20), 3409.
- Kanhayyalal, D. y Jadhav, P. (2023). Comparative analysis of 2D and 3D vineyard yield prediction system using artificial intelligence (AI). *International Journal of Computing and Digital Systems*, 1-17.
- Lai, J.W., Ramli, H.R., Ismail, L.I. y Hasan, W.Z.W. (2022). Real-time detection of ripe oil palm fresh fruit bunch based on YOLOv4. *IEEE Access*, 10, 95763-95770.
- Lee, W.S. y Tardaguila, J. (2023). Pest and disease management. In *Advanced Automation for Tree Fruit Orchards and Vineyards* (pp. 93-118). Cham: Springer International Publishing.
- Lyu, S., Li, R., Zhao, Y., Li, Z., Fan, R. y Liu, S. (2022). Green citrus detection and counting in orchards based on YOLOv5-CS and AI edge system. *Sensors*, 22(2), 576.
- Milburn, L., Gamba, J., Fernandes, M. Y Semini, C. (2023, April). Computer-vision based real time waypoint generation for autonomous vineyard navigation with quadruped robots. In *2023 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)* (pp. 239-244). IEEE.
- Mohammed, M., Hamdoun, H. y Sagheer, A. (2023). Toward sustainable farming: implementing artificial intelligence to predict optimum water and energy requirements for sensor-based micro irrigation systems powered by solar PV. *Agronomy*, 13(4), 1081.
- Moreno-Bernal, P., Arizmendi-Peralta, P., Hernández-Aguilar, J.A., del Carmen Peralta-Abarca, J. y Velásquez-Aguilar, J.G. (2022, November). IoT platform for monitoring nutritional and weather conditions of avocado production. In *Ibero-American Congress of Smart Cities* (pp. 95-109). Cham: Springer Nature Switzerland.
- Moussaid, A., El Fkihi, S., Zennayi, Y., Lahlou, O., Kassou, I., Bourzeix, F. y Imani, Y. (2022, October). Machine learning applied to tree crop yield prediction using field data and satellite imagery: A Case Study in a Citrus Orchard. In *Informatics* (Vol. 9, No. 4, p. 80). MDPI.
- Mu, X. y He, L. (2022). An advanced cartesian robotic system for precision apple crop load management. In *2022 ASABE Annual International Meeting* (p. 1). American Society of Agricultural and Biological Engineers.
- Mubin, N.A., Nadarajoo, E., Shafri, H.Z.M. y Hamedianfar, A. (2019). Young and mature oil palm tree detection and counting using convolutional neural network deep learning method. *International Journal of Remote Sensing*, 40(19), 7500-7515.

Navya, P. y Sudha, D. (2023, January). Artificial intelligence-based robot for harvesting, pesticide spraying and maintaining water management system in agriculture using IoT. In AIP Conference Proceedings (Vol. 2523, No. 1, p. 020025). AIP Publishing LLC.

Neupane, C., Pereira, M., Koirala, A. y Walsh, K.B. (2023). Fruit sizing in orchard: A review from caliper to machine vision with deep learning. *Sensors*, 23(8), 3868.

Pérez-Bueno, M.L., Pineda, M., Vida, C., Fernández-Ortuño, D., Torés, J.A., De Vicente, A. y Barón, M. (2019). Detection of white root rot in avocado trees by remote sensing. *Plant disease*, 103(6), 1119-1125.

Ramírez-Mejía, D., Levers, C. y Mas, J.F. (2022). Spatial patterns and determinants of avocado frontier dynamics in Mexico. *Regional Environmental Change*, 22(1), 28.

Rouš, R., Peller, J., Polder, G., Hageraats, S., Ruigrok, T. y Blok, P.M. (2023). Apple scab detection in orchards using deep learning on colour and multispectral images. *arXiv preprint arXiv:2302.08818*.

Salgadoe, A. S. A., Robson, A. J., Lamb, D. W., Dann, E. K., & Searle, C. (2018). Quantifying the severity of phytophthora root rot disease in avocado trees using image analysis. *Remote Sensing*, 10(2), 226.

Sastrohartono, H., Suryotomo, A.P., Saifullah, S., Suparyanto, T., Perbangsa, A.S. y Pardamean, B. (2022, August). Drone application model for image acquisition of plantation areas and oil palm trees counting. In 2022 International Conference on Information Management and Technology (ICIMTech) (pp. 167-171). IEEE.

Shah, S.S.A., Zeb, A.; Qureshi, W.S., Arslan, M.; Malik, A.U., Alasmary, W. y Alanazi, E. (2020). Towards fruit maturity estimation using NIR spectroscopy. *Infrared Phys. Technol.* 2020, 111, 103479.

Sheikh, S.I., Hassebo, A., Hossain, F. y Ren, K. (2022, April). Detection of red palm weevil infestation in palm trees. In ASEE-NE 2022.

Tang, Y., Chen, M., Wang, C., Luo, L., Li, J., Lian, G. y Zou, X. (2020). Recognition and localization methods for vision-based fruit picking robots: a review. *Frontiers in Plant Science*, 11.

Vaudour, E. (2002). The quality of grapes and wine in relation to geography: Notions of terroir at various scales. *J. Wine Res.*, 13, 117–141.

Vijayakumar, V., Ampatzidis, Y. y Costa, L. (2023). Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning. *Smart Agricultural Technology*, 3, 100077.

Wu, F., Duan, J., Ai, P., Chen, Z., Yang, Z. y Zou, X. (2022). Rachis detection and three-dimensional localization of cut off point for vision-based banana robot. *Computers and Electronics in Agriculture*, 198, 107079.

Xiong, Z., Feng, Q., Li, T., Xie, F., Liu, C., Liu, L. y Zhao, C. (2022). Dual-Manipulator optimal design for apple robotic harvesting. *Agronomy*, 12(12), 3128.

Yin, H., Sun, Q., Ren, X., Guo, J., Yang, Y., Wei, Y. y Zhong, M. (2023). Development, integration, and field evaluation of an autonomous citrus-harvesting robot. *Journal of Field Robotics*.

Zhang, K., Lammers, K., Chu, P., Dickinson, N., Li, Z. y Lu, R. (2022, October). Algorithm design and integration for a robotic apple harvesting system. In 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (pp. 9217-9224). IEEE.

Zhou, Z., Zahid, U., Majeed, Y., Mustafa, S., Sajjad, M.M., Butt, H.D. y Fu, L. (2023). Advancement in artificial intelligence for on-farm fruit sorting and transportation. *Frontiers in Plant Science*, 14.



RICARDO HUGO LIRA-SALDIVAR - Doctor (Ph.D) en Ecología por la Universidad de California, Davis, USA. Diplomado en la Universidad Ben-Gurion de Israel. Con una Maestría (M.C.) en Uso y Conservación del Agua, del Instituto Tecnológico y de Estudios Superiores de Monterrey (ITESM), México. Ingeniero Agrónomo por la Universidad Autónoma Agraria Antonio Narro (UAAAN) de Saltillo, México. Labora en el Departamento de Biociencias y Agrotecnología del Centro de Investigación en Química Aplicada (CIQA), en Saltillo, México.



FRANCISCO MARCELO LARA-VIVEROS - Doctor en Ciencias en Fisiología Vegetal por el Colegio de Postgraduados (CP) Texcoco, México. Maestría en Ciencias en Producción Agroalimentaria en el Trópico e Ingeniero en Sistemas de Producción Agropecuaria por la Universidad Veracruzana, Veracruz, México. Actualmente adscrito al Departamento de Biociencias y Agrotecnología del Centro de Investigación en Química Aplicada en Saltillo, México.



Inteligencia Artificial en Agricultura

Uso de Algoritmos, Drones y Biosensores

🌐 www.atenaeditora.com.br
✉ contato@atenaeditora.com.br
📷 @atenaeditora
📘 www.facebook.com/atenaeditora.com.br



Inteligencia Artificial en Agricultura

Uso de Algoritmos, Drones y Biosensores

🌐 www.atenaeditora.com.br
✉ contato@atenaeditora.com.br
📷 @atenaeditora
📘 www.facebook.com/atenaeditora.com.br