GRUPO BLR

INTELIGENCIA ARTIFICIAL Y BIG DATA EN LA AGRICULTURA

ISBN: 978-9907-802-63-4

Wilmer Henry Illescas Espinoza
Jussen Facuy Delgado
Mónica Alexandra Nugra Betancourth

2026

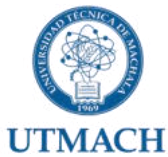
INTELIGENCIA ARTIFICIAL Y BIG DATA EN LA AGRICULTURA

Wilmer Henry Illescas Espinoza

Jussen Facuy Delgado

Mónica Alexandra Nugra Betancourth

AUTORES



Este libro ha sido debidamente examinado y valorado en la modalidad doble par ciego con fin de garantizar la calidad científica.

©Grupo Editorial BLR
Universidad Técnica de Machala
Riobamba – Ecuador
Correo: publicaciones@grupoblr.com
https://grupoblr.com/libros-investigo
REPOSITORIO



Illescas, W., Facuy., J., Nugra, M. (2026) Inteligencia Artificial y Big Data en la Agricultura. Grupo Editorial BLR.

© Wilmer Henry Illescas Espinoza
Jussen Facuy Delgado
Mónica Alexandra Nugra Betancourth

Inteligencia Artificial y Big Data en la Agricultura.

ISBN: 978-9907-802-63-4

El copyright promueve la libertad de expresión, protege la diversidad de ideas y conocimiento, además apoya la libre expresión. Se prohíbe de manera rigurosa la producción o el almacenamiento de esta publicación, ya sea en su totalidad o en parte, está estrictamente prohibido por ley, incluyendo el diseño de la portada, así como su difusión a través de cualquiera de sus medios, ya sean electrónicos, mecánicos, ópticos, de grabación o incluso de fotocopia, sin permiso de los propietarios de los derechos de autor.

Filiación de autores

Wilmer Henry Illescas Espinoza

Universidad Técnica de Machala

Correo Electrónico: willescas@utmachala.edu.ec

ORCID: https://orcid.org/0000-0001-5171-7210

Jussen Facuy Delgado

Universidad Técnica de Machala

Correo Electrónico: jussen.facuyd@ug.edu.ec

ORCID: https://orcid.org/0000-0003-1138-4823

Mónica Alexandra Nugra Betancourth

Universidad Técnica de Machala

Correo Electrónico: manugra@utmachala.edu.ec

ORCID: https://orcid.org/0000-0001-6148-6516

ÍNDICE

ÍNDICE ..... **i**

ÍNDICE DE TABLAS ..... **vi**

ÍNDICE DE FIGURAS ..... **vii**

INTRODUCCIÓN ..... **xi**

CAPÍTULO I **19**

1 INTELIGENCIA ARTIFICIAL Y BIG DATA EN LA AGRICULTURA **19**

1.1 Transformación digital del sistema agroalimentario 20

1.2 Fundamentos conceptuales de la Agricultura 4.0 22

1.3 Blockchain y trazabilidad en los sistemas agroalimentarios 26

1.4 Gemelos digitales (Digital Twins) aplicados a la agricultura 31

1.5 Aplicaciones de la IA en la predicción de rendimientos 33

1.5.1 Principales enfoques tecnológicos 33

1.5.2 IA en la optimización de procesos 34

1.5.3 Ecosistema de datos agrícolas 35

1.5.4 Tipos de datos utilizados 36

1.5.5 Ejemplos de implementación en distintas regiones 37

1.5.6 Beneficios concretos en productividad, eficiencia y sostenibilidad. 38

1.6 Impacto económico de la inteligencia artificial en la agricultura 40

1.7 Optimización de recursos mediante Inteligencia Artificial en la Agricultura 41

1.7.1 Principales estrategias tecnológicas 43

1.7.2 Beneficios cuantificables 45

1.8 Control de plagas mediante Inteligencia Artificial en la Agricultura 46

1.8.1 Modelos predictivos para el control de plagas y enfermedades. 47

1.8.2 Detección temprana y diagnóstico automatizado..... 50

1.8.3 Visión artificial y redes neuronales convolucionales para el diagnóstico 50

1.8.4 Fundamentos de las redes neuronales convolucionales 51

1.8.5 Aplicaciones de CNN en la detección de enfermedades agrícolas …….57

1.8.6 1.8.4 Monitoreo continuo con drones e IoT..... 62

1.8.7 Caso aplicado: reconocimiento de Sigatoka Negra en banano mediante Deep Learning 62

1.8.8 Contexto fitosanitario del banano y la Sigatoka Negra..... 63

1.8.9 Aplicación precisa de tratamientos 95

1.8.10 Impacto en la sostenibilidad y productividad 95

1.9 Casos de éxito en el uso de Big Data en agricultura 97

1.9.1 John Deere y la agricultura de precisión en Estados Unidos 97

1.9.2 Agrosmart en América Latina 99

1.9.3 Climate FieldView y la predicción del rendimiento 99

1.9.4 Proyecto 365FarmNet en Europa 100

1.10 Gobernanza de datos agrícolas y plataformas digitales 102

1.11 Perspectivas futuras de la agricultura inteligente..... 105

CAPÍTULO II 108

2 AGRICULTURA SOSTENIBLE Y TECNOLOGÍAS VERDES 108

2.1 Tecnologías para la gestión eficiente del agua (riego inteligente)..... 110

2.2 Energías renovables en la agricultura (paneles solares, biogás)..... 115

2.2.1 Energía solar 115

2.2.2 Biogas 117

2.3 Agricultura vertical y cultivos en entornos controlados 118

2.3.1 Fundamentos tecnológicos 120

2.3.2 Modelos de producción y eficiencia 121

2.3.3 Sostenibilidad y limitaciones 121

2.4 Impacto ambiental y social de las tecnologías agrícolas 122

2.4.1 Inteligencia artificial y adaptación al cambio climático 123

2.4.2 Impacto ambiental 124

2.4.3 Impacto social 126

2.4.4 Perspectiva crítica y sostenibilidad inclusiva 127

2.5 Desafíos y perspectivas futuras de la agricultura tecnológica . 129

2.6 Gobernanza y ética de los datos agrícolas 129

2.7 Agricultura autónoma y robótica inteligente 131

2.8 Conclusiones 134

2.9 Anexos 142

2.9.1 Anexo A 142

2.9.2 Anexo B 143

BIBLIOGRAFÍA 144

ÍNDICE DE TABLAS

Tabla 1. Impactos económicos de la inteligencia artificial en la agricultura. 40

Tabla 2. Aplicaciones de la inteligencia artificial para la optimización de recursos en la agricultura. 42

Tabla 3. Comparación de clasificadores. 60

Tabla 4. Escala de los grados de afectación o estadios. 68

Tabla 5. Características para entrenar el modelo. 76

Tabla 6. Comparación de plataformas de Big Data aplicadas a la agricultura. 100

Tabla 7. Tecnologías verdes aplicadas a la agricultura sostenible. 109

Tabla 8. Tendencias tecnológicas emergentes en la agricultura hacia 2030–2040. 132

ÍNDICE DE FIGURAS

Figura 1. Arquitectura de agricultura inteligente basada en integración de drones, IoT y análisis de datos. 30

Figura 2. Red de categorías de las variables de investigación. 51

Figura 3. Estructura básica de Redes Neuronales Convolucionales. 52

Figura 4. Ejemplo de convolución con una imagen de entrada de 4x4 y un kernel de 3x3. Naranjo-Torres y otros. 2020..... 53

Figura 5. Diagrama de Arquitectura CNN en cada una de sus fases. Jiang y Li, 2020. 54

Figura 6. Tecnicas de Machine Learning utilizadas en la agricultura de precisión. Sharma y otros, 2021..... 55

Figura 7. Diagrama de Flujo de una implementación de Aprendizaje Profundo utilizando CNN. Saleem, Potgieter y Arif, 2019. 56

Figura 8. Evolución histórica de varios modelos desde 2012. Saleem, Potgieter y Arif, 2019..... 57

Figura 9. Estadística de uso de las redes..... 58

Figura 10. Banano en cajas para exportación (destino). 63

Figura 11. Bananos para postre: Exportación por continente desde el 1998 hasta el 2000. 64

Figura 12. Estadios de evolución de la Sigatoka Negra. 65

Figura 13. Ciclo patológico de la Sigatoka Negra. 66

Figura 14. Escala o estadios de la Sigatoka Negra según Fouré (1985). 67

Figura 15. Ejemplo de imágenes capturadas para cada una de las 6 escalas de la enfermedad Sigatoka. 71

Figura 16. Herramienta desarrollada en JavaScript para delimitar la región de análisis de la enfermedad Sigatoka. 72

Figura 17. Esquema general del sistema de visión artificial para detección del grado de la enfermedad Sigatoka. 73

Figura 18. Flujo del procesamiento de una imagen. 74

Figura 19. Curvas de perdida y exactitud para la variación 1 del modelo. 90

Figura 20. Curvas de perdida y exactitud para la variación 2 del modelo.Curvas de perdida y exactitud para la variación 2 del modelo. 91

Figura 21. Curvas de perdida y exactitud para la variación 3 del modelo. 92

Figura 22. Matrices de confusión obtenidas en la validación de las variaciones 1, 2 y 3 del modelo. 92

Figura 23. Curva ROC obtenida para la variación 3 del modelo. 93

Figura 24. Arquitectura cliente servidor implementada para desplegar en productivo los modelos entrenados. 94

Figura 25. Ecosistema tecnológico de la Agricultura Inteligente 4.0. 96

Figura 26. Tractor con tecnología de vanguardia. 98

Figura 27. Flujo de datos en sistemas de agricultura digital. 103

Figura 28. Modelo conceptual de agricultura inteligente basada en inteligencia artificial y Big Data. 106

Figura 29. Arquitectura de sistema de un modelo IoT de riego. . 110

Figura 30. Arquitectura propuesta de sistema de agricultura inteligente basado en IoT. 112

Figura 31. Paneles solares para el riego. 115

Figura 32. Paneles solares, vista aérea de la parcela. 116

Figura 33. Diseño de biodigestor. 117

Figura 34. Cultivo controlado. 118

Figura 35. Sistema de agricultura vertical en entorno controlado con iluminación LED y cultivo hidropónico..... 119

Figura 36. El agricultor en la innovación del agro. 122

Figura 37. Diagrama de un ecosistema de producción sostenible. 124

Figura 38. Modelo conceptual de agricultura sostenible basada en tecnologías verdes y digitales. 128

INTRODUCCIÓN

Hablar de agricultura es hablar de una de las actividades más antiguas de la humanidad, pero también de una de las que enfrenta mayores transformaciones en el presente. Durante siglos, producir alimentos dependió principalmente del conocimiento acumulado por los agricultores, de la observación del clima, de la calidad del suelo y de una experiencia transmitida de generación en generación. Ese conocimiento continúa siendo fundamental. Sin embargo, el escenario en el que actualmente se desarrolla la agricultura es considerablemente más complejo: una población mundial creciente, cambios en los patrones climáticos, presión sobre las fuentes de agua, degradación de los suelos, aparición y propagación de enfermedades agrícolas, aumento de los costos de producción y una demanda cada vez mayor por producir alimentos de manera sostenible.

Frente a esta realidad, resulta difícil pensar que los sistemas agrícolas del futuro podrán gestionarse únicamente con las mismas herramientas empleadas durante las décadas anteriores. La agricultura necesita producir más, pero el desafío consiste en hacerlo sin asumir que siempre habrá más suelo disponible, más agua, más fertilizantes o más mano de obra. Precisamente allí comienza a cobrar importancia la tecnología. No como un sustituto automático del conocimiento agronómico o de la experiencia humana, sino como una herramienta capaz de ampliar la información disponible y mejorar la calidad de algunas decisiones.

En los últimos años, términos como inteligencia artificial, Big Data, Internet de las Cosas, aprendizaje automático, drones, visión artificial o

robótica han dejado de pertenecer exclusivamente al ámbito de la informática. Hoy forman parte de discusiones relacionadas con producción agrícola, gestión del agua, sanidad vegetal, planificación de cosechas y sostenibilidad. Esta convergencia entre agricultura y tecnología ha dado origen a conceptos como agricultura inteligente, agricultura de precisión y Agricultura 4.0, todos ellos vinculados por una idea común: utilizar información obtenida del entorno productivo para tomar decisiones más oportunas y mejor fundamentadas.

En una explotación agrícola moderna pueden generarse datos prácticamente de manera continua. Un sensor instalado en el suelo puede registrar humedad o temperatura; una estación meteorológica puede medir precipitación, radiación y condiciones atmosféricas; un dron puede obtener imágenes detalladas del cultivo; un satélite puede observar extensiones completas de terreno; una máquina agrícola puede registrar información sobre rendimiento y consumo; y un teléfono móvil puede convertirse en una herramienta para capturar imágenes de una planta afectada por una enfermedad. El problema, por tanto, ya no consiste solamente en obtener datos. El verdadero reto es convertirlos en información útil.

Considerando lo anterior, es donde la inteligencia artificial y el Big Data se tornan relevantes. Los algoritmos de aprendizaje automático pueden identificar relaciones que no siempre resultan evidentes mediante una observación convencional. A partir de datos históricos y actuales, estos sistemas pueden contribuir a estimar rendimientos, identificar patrones de estrés en los cultivos, reconocer enfermedades, optimizar el riego o recomendar una aplicación más localizada de determinados insumos. El

Big Data, por su parte, permite integrar fuentes de información de naturaleza muy diferente y analizarlas conjuntamente, creando una visión más amplia del sistema productivo.

Pero conviene evitar una visión excesivamente optimista de esta transformación. La incorporación de tecnología no convierte automáticamente una explotación agrícola en más productiva ni más sostenible. Los modelos dependen de los datos con los que son construidos; los sensores pueden fallar; una red neuronal puede ofrecer resultados satisfactorios en determinadas condiciones y comportarse de manera deficiente en otras; los pequeños productores pueden carecer de conectividad o de recursos para acceder a determinadas soluciones; y la concentración de información en grandes plataformas tecnológicas plantea preguntas que no son exclusivamente técnicas. ¿A quién pertenecen los datos que genera una finca? ¿Quién puede utilizarlos? ¿Qué ocurre cuando una decisión productiva comienza a depender de un algoritmo desarrollado por una empresa externa? Estas cuestiones forman también parte de la agricultura digital.

Por esta razón, este libro no pretende presentar la inteligencia artificial como una solución milagrosa para los problemas del sector agrícola. El propósito es analizar sus posibilidades desde una perspectiva aplicada, pero también reconocer sus límites. La tecnología recobra sentido cuando responde a necesidades concreta. Un modelo con una elevada complejidad estadística puede ser interesante, pero si requiere una infraestructura imposible de utilizar en el área o si sus resultados no ayudan a tomar decidir, su utilidad práctica será limitada. De la misma

manera, una solución aparentemente sencilla puede producir un impacto considerable cuando logra resolver un problema real del agricultor.

Esta relación entre problema agrícola y solución tecnológica puede observarse con claridad en el diagnóstico de enfermedades vegetales. Tradicionalmente, reconocer el estado sanitario de un cultivo ha dependido en gran medida de la experiencia de técnicos y productores. La visión artificial introduce otra posibilidad: utilizar imágenes de las plantas para identificar características relacionadas con una enfermedad y posteriormente clasificarlas mediante algoritmos de aprendizaje profundo. Este campo ha evolucionado con rapidez gracias al desarrollo de las redes neuronales convolucionales, capaces de aprender patrones directamente a partir de imágenes.

Dentro del libro se aborda esta aplicación de una manera particular mediante un caso relacionado con el cultivo de banano y la Sigatoka Negra. Este ejemplo no se incorpora únicamente como una descripción tomada de la literatura. Se presenta una experiencia experimental en la que se recopilaron imágenes en campo, se construyó una base de datos, se delimitaron regiones de análisis y se utilizó una arquitectura ResNet18 para estudiar la posibilidad de clasificar diferentes niveles de afectación de la enfermedad. La experiencia permitió observar algo que resulta igualmente importante en el desarrollo de inteligencia artificial: no todos los problemas se resuelven simplemente entrenando un modelo. Al aumentar el número de clases y tratar de diferenciar estadios visualmente próximos, la capacidad de generalización disminuyó; al agrupar los niveles, el desempeño mejoró de manera considerable.

Este tipo de resultado resulta útil porque muestra la distancia que existe entre una demostración tecnológica y una aplicación agrícola real. En condiciones controladas, una imagen puede tener iluminación uniforme, fondo homogéneo y una lesión claramente visible. En el campo ocurre exactamente lo contrario: cambia la luz, cambia el ángulo de captura, existen daños producidos por distintas causas y las diferencias entre dos estados de una enfermedad pueden ser visualmente pequeñas. Por ello, trabajar con inteligencia artificial en agricultura exige combinar conocimientos informáticos con conocimientos agronómicos. Ninguna de las dos áreas, por sí sola, es suficiente.

El caso del banano también permite acercar la discusión tecnológica a una realidad productiva concreta. La Sigatoka Negra constituye un problema fitosanitario relevante y su manejo está relacionado con monitoreo, condiciones ambientales, decisiones de tratamiento y utilización de productos químicos. En ese contexto, una herramienta de apoyo al diagnóstico no debería entenderse como un reemplazo del técnico agrícola, sino como un mecanismo que puede facilitar la captura de información, ayudar en el seguimiento del cultivo y, eventualmente, integrarse con sistemas de alerta o plataformas de gestión agrícola. Esa diferencia es importante: la inteligencia artificial es más valiosa cuando fortalece la capacidad de decisión de las personas que cuando pretende sustituirla indiscriminadamente.

La transformación tecnológica de la agricultura, sin embargo, no puede analizarse únicamente desde la inteligencia artificial. La sostenibilidad de los sistemas productivos exige considerar también cómo se utilizan recursos fundamentales como el agua y la energía. Por ello, una parte

importante de esta obra está dedicada al riego inteligente, las energías renovables, el biogás, la agricultura vertical y los sistemas de producción en ambientes controlados. El interés que despiertan estas tecnologías proviene de una preocupación bastante concreta: producir alimentos sin continuar aumentando de manera indefinida la presión sobre los recursos naturales.

El agua constituye quizá el ejemplo más evidente. No basta con disponer de un sistema de riego; es necesario saber cuándo regar, cuánto regar y en qué zonas hacerlo. Combinar sensores, modelos de evapotranspiración, información climatológica y algoritmos de análisis permite avanzar hacia sistemas en que el riego responde con mayor precisión a las necesidades de la producción. Una lógica similar puede aplicarse a los fertilizantes, los pesticidas y otros insumos. El objetivo no consiste necesariamente en eliminar su utilización, sino en evitar aplicaciones innecesarias y mejorar la relación entre productividad y consumo de recursos.

Algo semejante ocurre con la energía. Los sistemas fotovoltaicos y el aprovechamiento de residuos para generación de biogás muestran que la innovación agrícola no depende exclusivamente de los algoritmos. La transición tecnológica del sector requiere integrar distintas soluciones: unas producen información, otras automatizan decisiones y otras modifican la manera en que se utilizan recursos físicos. Desde esta perspectiva, la agricultura inteligente y la agricultura sostenible no deberían considerarse caminos separados. Ambas terminan convergiendo cuando la tecnología se utiliza para producir de manera más eficiente y con menor impacto ambiental.

Esta convergencia también plantea interrogantes sociales. La agricultura digital puede generar oportunidades, pero existe el riesgo de que sus beneficios se concentren en productores que ya poseen infraestructura, conectividad, capital y conocimientos técnicos. La brecha digital rural no desaparece porque exista una nueva aplicación o un nuevo sensor. Una tecnología puede ser técnicamente excelente y, aun así, resultar inútil para un productor que no puede financiarla, mantenerla o interpretarla. Por esa razón, la discusión sobre innovación agrícola debe incluir necesariamente capacitación, accesibilidad, transferencia tecnológica y políticas públicas.

El libro se desarrolla alrededor de estas ideas. El primer capítulo analiza la relación entre inteligencia artificial, Big Data y agricultura, comenzando por la transformación digital de los sistemas agroalimentarios y avanzando hacia Agricultura 4.0, blockchain, gemelos digitales, predicción de rendimientos y optimización de recursos. Posteriormente se profundiza en el control de plagas y enfermedades, la visión artificial y las redes neuronales convolucionales, incluyendo el caso aplicado de reconocimiento de Sigatoka Negra en banano. Finalmente, se revisan experiencias de utilización de Big Data, problemas relacionados con gobernanza de datos y algunas de las tendencias que están configurando el futuro de la agricultura inteligente.

El segundo capítulo hace énfasis en la sostenibilidad. Se estudian tecnologías enfocadas a una gestión más eficiente del agua, las alternativas energéticas como la energía solar y el biogás, sistemas de agricultura vertical y producción en ambientes controlados, así como los

impactos ambientales y sociales vinculados a la transformación tecnológica del agro. También se consideran aspectos vinculados a la gobernanza, ética, automatización y la robótica agrícola, entendiendo que el futuro del sector dependerá de la capacidad de innovar como de la forma en que esos avances sean incorporados a los sistemas productivos.

En definitiva, cuando se trata de tendencias del agro no significa imaginar campos en los que las personas hayan desaparecido y todo sea gestionado por máquinas. El escenario más considerable es otro: agricultores, investigadores y entes de la gobernanza utilizando herramientas cada vez más sofisticadas para mejorar la comprensión de sistemas complejos. La tecnología puede ampliar la capacidad de observar, anticipar y decidir, pero las decisiones continúan teniendo consecuencias económicas, ambientales y humanas.

En este contexto, se busca informar y comprender qué problemas se pueden resolver, qué información necesitan los agricultores, cuáles son sus limitaciones y bajo qué términos pueden contribuir realmente a construir una agricultura más productiva y sostenible. La innovación no está en llenar el campo de sensores, drones o algoritmos. Está en lograr que los datos se conviertan en conocimiento, sabiduría, que ese conocimiento mejore la toma de decisiones y que esas decisiones permitan producir alimentos sin olvidar las personas y al entorno del que depende la actividad agrícola.

CAPÍTULO I

1 INTELIGENCIA ARTIFICIAL Y BIG DATA EN LA AGRICULTURA

La agricultura global enfrenta desafíos sin precedentes en el siglo XXI. Según las proyecciones más recientes de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2022), se estima que para 2050 la demanda mundial de alimentos aumentará en un alarmante 60% debido al crecimiento poblacional acelerado, mientras que los recursos naturales disponibles para la producción agropecuaria se vuelven cada vez más escasos y los efectos del cambio climático se intensifican de manera preocupante. Este escenario crítico plantea una pregunta fundamental: ¿cómo podrá la humanidad alimentar a casi 10 mil millones de personas en un planeta con recursos limitados y un clima cada vez más impredecible?

La respuesta a este desafío multidimensional puede encontrarse en la adopción masiva de tecnologías digitales avanzadas. En este contexto, la Inteligencia Artificial (IA) y el Big Data emergen como herramientas transformadoras capaces de revolucionar los sistemas agroalimentarios tradicionales, haciendo posible una nueva era de agricultura inteligente caracterizada por su precisión milimétrica, eficiencia sin precedentes y sostenibilidad a largo plazo (Liakos et al., 2018). Estas tecnologías no representan simplemente una mejora incremental de los métodos agrícolas convencionales, sino que constituyen un cambio de paradigma completo en la forma en que cultivamos, monitoreamos y gestionamos nuestros recursos alimentarios.

1.1 Transformación digital del sistema agroalimentario

La transformación digital del sector agroalimentario constituye uno de los cambios estructurales más significativos en la evolución reciente de la agricultura global. Durante gran parte del siglo XX, los sistemas agrícolas se caracterizaron por una producción basada en la mecanización, el uso intensivo de insumos químicos y la expansión de la superficie cultivada. Sin embargo, en las últimas décadas ha emergido un nuevo paradigma productivo basado en la integración de tecnologías digitales avanzadas, análisis de datos y automatización inteligente.

Este proceso de digitalización agrícola ha sido impulsado por múltiples factores. En primer lugar, el crecimiento acelerado de la población mundial ha incrementado la presión sobre los sistemas de producción de alimentos. Según estimaciones de la FAO (2022), la población mundial podría superar los 9.700 millones de personas para el año 2050, lo que implicará un aumento significativo en la demanda de alimentos, agua y recursos agrícolas.

En segundo lugar, el cambio climático ha introducido un nuevo nivel de incertidumbre en los sistemas productivos agrícolas. Eventos climáticos extremos como sequías prolongadas, inundaciones, olas de calor y cambios en los patrones de precipitación afectan directamente la productividad de los cultivos. En este contexto, la capacidad de anticipar y gestionar estos riesgos mediante sistemas de análisis predictivo se ha convertido en una prioridad estratégica para el sector agrícola (Basso & Antle, 2020).

La digitalización agrícola también ha sido impulsada por el desarrollo de tecnologías de recopilación de datos cada vez más sofisticadas. Los sensores IoT, las estaciones meteorológicas automatizadas, los drones agrícolas y los satélites de observación terrestre generan enormes volúmenes de información sobre las condiciones ambientales y el estado de los cultivos. Estos datos constituyen la base sobre la cual se desarrollan los sistemas de inteligencia agrícola basados en inteligencia artificial y Big Data (Wolfert et al., 2017).

Además, el avance de la computación en la nube y el desarrollo de algoritmos de aprendizaje automático han permitido analizar grandes volúmenes de datos agrícolas con una velocidad y precisión sin precedentes. Estos sistemas pueden identificar patrones complejos en los datos y generar recomendaciones automatizadas que ayudan a los agricultores a optimizar sus decisiones de manejo agrícola (Liakos et al., 2018).

Desde una perspectiva económica, la digitalización del sector agrícola también ha dado lugar al surgimiento de un nuevo ecosistema tecnológico conocido como *AgTech*. Este ecosistema incluye empresas tecnológicas especializadas en sensores agrícolas, plataformas de análisis de datos, robótica agrícola, biotecnología y sistemas de gestión digital de cultivos. Según estimaciones recientes, el mercado global de tecnologías agrícolas digitales podría superar los 40 mil millones de dólares en los próximos años (Kumar et al., 2023).

Las cifras actuales revelan la urgencia de esta transformación tecnológica. Según datos contundentes de la FAO (2021), las pérdidas

anuales en cultivos a nivel global debido a plagas, enfermedades y manejo ineficiente superan la astronómica cifra de 220 mil millones de dólares estadounidenses. Estas pérdidas colosales no solo representan un golpe devastador para la economía agrícola mundial, sino que además constituyen una amenaza directa para la seguridad alimentaria de millones de personas, particularmente en regiones en desarrollo. Estas estadísticas evidencian de manera irrefutable la necesidad imperiosa de adoptar soluciones innovadoras basadas en datos que permitan optimizar el uso de recursos escasos, predecir riesgos potenciales con antelación y maximizar la productividad por unidad de superficie cultivada.

La convergencia sinérgica de tecnologías disruptivas como el Internet de las Cosas (IoT), el aprendizaje automático (machine learning), el análisis predictivo avanzado y la computación en la nube está redefiniendo radicalmente lo que los expertos denominan Agricultura 4.0 (Wolfert et al., 2017). Diversos estudios han demostrado que la integración de modelos predictivos y análisis de datos avanzados permite optimizar la gestión de recursos y mejorar la eficiencia de los sistemas productivos y ambientales (Facuy & Diego, 2026).

1.2 Fundamentos conceptuales de la Agricultura 4.0

El concepto de Agricultura 4.0 surge como una extensión del paradigma de la Industria 4.0 aplicado al sector agropecuario. La Industria 4.0 se basa en la digitalización de los procesos industriales mediante la integración de sistemas ciberfísicos, sensores inteligentes y análisis de datos, en este contexto, la Agricultura 4.0 busca aplicar estos mismos principios a la producción agrícola.

Por lo tanto, en la Agricultura 4.0, los sistemas agrícolas se transforman en entornos altamente digitalizados donde múltiples tecnologías interactúan de manera simultánea para optimizar los procesos productivos, como sensores instalados en el campo para recopilar información sobre variables ambientales, drones agrícolas monitorean el estado de los cultivos o plataformas de análisis de datos procesan esta información para generar recomendaciones de manejo agrícola.

Uno de los elementos centrales de la Agricultura 4.0 es la capacidad de integrar información proveniente de múltiples fuentes de datos. Estos datos pueden incluir información climática, características del suelo, patrones de crecimiento vegetal, historial de rendimiento de cultivos y registros de prácticas agronómicas. La combinación de estas fuentes de información permite desarrollar modelos predictivos capaces de anticipar cambios en el comportamiento de los sistemas agrícolas.

Además, la Agricultura 4.0 incorpora tecnologías emergentes como la robótica agrícola, los sistemas autónomos de cultivo y la automatización inteligente de procesos. Los robots agrícolas pueden realizar tareas como la siembra, el monitoreo de cultivos, la aplicación de fertilizantes y la cosecha con un alto nivel de precisión, reduciendo la dependencia de la mano de obra humana y aumentando la eficiencia productiva.

Desde una perspectiva ambiental, la Agricultura 4.0 también ofrece oportunidades para mejorar la sostenibilidad de los sistemas agrícolas. La optimización del uso de recursos como el agua, los fertilizantes y la energía permite reducir el impacto ambiental de la producción agrícola

y mejorar la resiliencia de los sistemas productivos frente al cambio climático (Pretty et al., 2018).

El papel de la IA y el Big Data en la agricultura moderna es tan amplio como revolucionario. Las aplicaciones prácticas de estas tecnologías abarcan desde la predicción precisa de rendimientos agrícolas hasta la detección temprana de enfermedades en cultivos, pasando por la gestión inteligente de recursos hídricos cada vez más escasos y la dosificación óptima de fertilizantes (Zhang et al., 2019). Un ejemplo elocuente de este potencial transformador lo proporcionan los algoritmos de deep learning (aprendizaje profundo) que, al analizar imágenes satelitales y fotografías capturadas por drones, pueden identificar estrés hídrico en cultivos con una precisión que supera el 95% (Maimaitijiang et al., 2020). Esta capacidad de diagnóstico precoz permite a los agricultores intervenir de manera oportuna, evitando pérdidas significativas en sus cosechas.

Por su parte, el Big Data agrícola permite integrar y correlacionar información proveniente de múltiples fuentes heterogéneas, incluyendo sensores de suelo inalámbricos, estaciones meteorológicas automatizadas, imágenes multiespectrales de alta resolución y datos históricos de rendimiento (Kamilaris et al., 2017). Esta integración holística de datos diversos genera un conocimiento profundo sobre los sistemas agrícolas que trasciende con creces las capacidades de análisis humano tradicional, permitiendo identificar patrones complejos, predecir tendencias y optimizar procesos con un nivel de detalle microscópico.

La evidencia científica respalda de manera contundente los beneficios de esta transformación digital. Un estudio seminal publicado en Nature Sustainability demostró de manera concluyente que las granjas que implementaron sistemas de agricultura de precisión basados en IA lograron reducir el consumo de agua en un significativo 25% y el uso de fertilizantes en un 20%, todo esto sin comprometer en absoluto los niveles de productividad (Basso & Antle, 2020). Estos resultados no son meramente teóricos, sino que se traducen en beneficios económicos tangibles para los agricultores y en avances concretos hacia la sostenibilidad ambiental.

En el panorama tecnológico actual, plataformas avanzadas como IBM Watson Agro y The Climate Corporation están liderando esta revolución agrícola digital mediante la implementación de modelos predictivos sofisticados que ayudan a los agricultores a tomar decisiones informadas basadas en datos históricos, condiciones actuales del terreno y pronósticos climáticos hiperlocales (IBM, 2021). Estas herramientas no solo mejoran la rentabilidad de las operaciones agrícolas, sino que además contribuyen a reducir significativamente el impacto ambiental de la agricultura intensiva.

Sin embargo, el potencial completo de la IA y el Big Data en agricultura está lejos de haberse agotado. Cada día surgen nuevas aplicaciones innovadoras que prometen revolucionar aún más este sector ancestral. Desde robots autónomos capaces de realizar cosechas selectivas hasta sistemas blockchain que garantizan la trazabilidad completa de los alimentos desde el campo hasta la mesa, las posibilidades son prácticamente ilimitadas (Kshetri, 2021).

1.3 Blockchain y trazabilidad en los sistemas agroalimentarios

La tecnología blockchain ha emergido en los últimos años como una herramienta innovadora para mejorar la transparencia, la seguridad y la trazabilidad dentro de las cadenas de suministro agrícolas. En términos generales, blockchain puede definirse como una base de datos distribuida y descentralizada que registra transacciones de manera segura y transparente mediante el uso de criptografía avanzada. Cada transacción se almacena en bloques interconectados que forman una cadena inmutable de registros, lo que dificulta la manipulación o alteración de la información registrada (Kshetri, 2021).

En el contexto del sector agroalimentario, la trazabilidad constituye un elemento fundamental para garantizar la seguridad alimentaria, la calidad de los productos y la confianza del consumidor. Tradicionalmente, los sistemas de trazabilidad agrícola han dependido de registros manuales o bases de datos centralizadas que pueden ser vulnerables a errores humanos, fraudes o pérdida de información. La incorporación de blockchain permite superar muchas de estas limitaciones al proporcionar un sistema transparente y verificable de seguimiento de productos desde su origen hasta su consumo final.

Uno de los principales beneficios de blockchain en la agricultura es su capacidad para registrar cada etapa del ciclo productivo dentro de la cadena de suministro. Desde la siembra del cultivo, la aplicación de fertilizantes y pesticidas, las condiciones climáticas durante el crecimiento del cultivo, hasta los procesos de cosecha, transporte y comercialización, toda esta información puede registrarse dentro de una

cadena de bloques accesible para todos los actores autorizados de la cadena de suministro.

Este enfoque permite mejorar significativamente la confianza entre productores, distribuidores, minoristas y consumidores. Por ejemplo, los consumidores pueden acceder mediante códigos QR a información detallada sobre el origen de los alimentos, las condiciones de producción y los estándares de calidad aplicados durante el proceso productivo.

Diversas empresas agroalimentarias han comenzado a implementar soluciones basadas en blockchain para mejorar la trazabilidad de sus productos. Un caso destacado es el programa *IBM Food Trust*, que utiliza tecnología blockchain para rastrear productos alimentarios dentro de la cadena de suministro global. Este sistema permite reducir significativamente el tiempo necesario para rastrear el origen de un producto contaminado, pasando de varios días a apenas unos segundos (IBM, 2021).

Desde una perspectiva ambiental y social, blockchain también puede contribuir a mejorar la sostenibilidad de los sistemas agrícolas. La posibilidad de verificar prácticas agrícolas sostenibles permite implementar sistemas de certificación más confiables para productos orgánicos, comercio justo y agricultura regenerativa.

No obstante, la adopción de blockchain en la agricultura también enfrenta desafíos importantes. Entre ellos destacan los costos de implementación, la necesidad de infraestructura digital adecuada y la interoperabilidad entre diferentes plataformas tecnológicas. Además, la implementación efectiva de estos sistemas requiere la colaboración

entre múltiples actores dentro de la cadena de suministro agroalimentaria.

Esta introducción busca proporcionar un marco comprensivo para entender cómo estas tecnologías están transformando la agricultura global, analizando sus aplicaciones más prometedoras, sus beneficios demostrados y los desafíos que aún persisten para su adopción masiva.

El análisis se estructura en cuatro ejes fundamentales que corresponden a las aplicaciones más transformadoras de estas tecnologías en el sector agrícola. En primer lugar, se examinarán en profundidad las aplicaciones de la IA en la predicción de rendimientos agrícolas, donde los algoritmos de aprendizaje automático están superando ampliamente los métodos tradicionales de pronóstico. Posteriormente, se analizará el crucial papel del análisis de datos masivos en la optimización de recursos escasos como el agua, los fertilizantes y los pesticidas, demostrando cómo la agricultura de precisión puede lograr más con menos.

Un tercer pilar del análisis se centrará en los modelos predictivos avanzados para el control de plagas y enfermedades, donde la combinación de imágenes multiespectrales, sensores IoT y algoritmos de computer vision está permitiendo identificar amenazas fitosanitarias con días o incluso semanas de anticipación. Finalmente, se presentarán casos de éxito concretos y documentados sobre el uso del Big Data en agricultura en diversas regiones del mundo, demostrando que esta no es una tecnología del futuro, sino una realidad operativa que ya está generando impactos positivos en campos de todo el planeta.

La relevancia de este análisis trasciende lo meramente tecnológico. En un mundo que enfrenta simultáneamente los desafíos del cambio climático, la escasez hídrica y el crecimiento poblacional, la adopción inteligente de estas tecnologías podría marcar la diferencia entre la seguridad alimentaria y la escasez crónica, entre la sostenibilidad ambiental y el colapso ecológico (Pretty et al., 2018). Por esta razón, comprender el potencial transformador de la IA y el Big Data en agricultura no es solo un ejercicio académico, sino una necesidad urgente para todos los actores involucrados en el sistema alimentario global, desde pequeños agricultores hasta responsables de políticas públicas.

En este contexto, el presente capítulo tiene como objetivo analizar el papel de la inteligencia artificial y el Big Data como tecnologías habilitadoras de la agricultura inteligente, explorando sus aplicaciones en la predicción de rendimientos, la optimización del uso de recursos, el control predictivo de plagas y enfermedades, así como diversos casos de éxito en la implementación de soluciones basadas en datos en distintos contextos agrícolas. Asimismo, se examinan los beneficios, limitaciones y desafíos asociados a la adopción de estas tecnologías en el sector agropecuario. El capítulo se estructura en cuatro secciones principales: en primer lugar, se analizan las aplicaciones de la IA en la predicción de rendimientos agrícolas; posteriormente, se aborda el papel del análisis de datos en la optimización de recursos; en tercer lugar, se examinan los modelos predictivos para el control de plagas y enfermedades; y finalmente, se presentan casos de éxito en el uso del Big Data en la agricultura.

La implementación de sistemas de agricultura inteligente requiere una infraestructura tecnológica capaz de integrar dispositivos de monitoreo, redes de comunicación y plataformas de análisis de datos. La arquitectura general de estos sistemas se ilustra en la Figura 1.

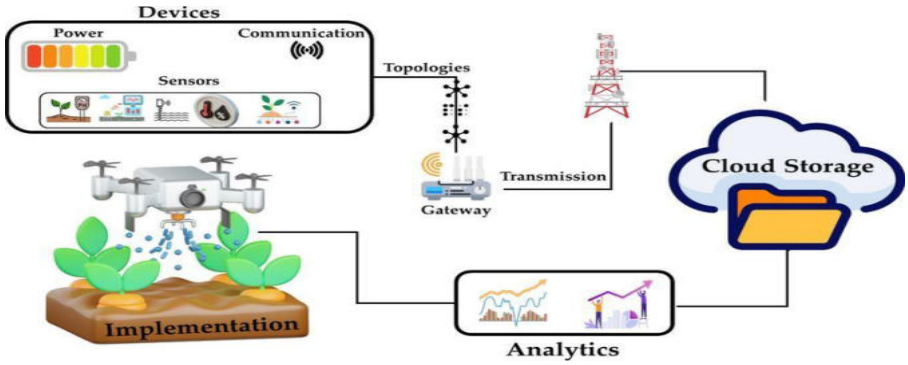


Figura 1. Arquitectura de agricultura inteligente basada en integración de drones, IoT y análisis de datos.

Nota. Adaptado de Future of sustainable farming: exploring opportunities and overcoming barriers in drone-IoT integration (Khan et al., 2024), Discover Sustainability, 5(1). https://doi.org/10.1007/s43621-024-00736-y.

La Figura 1 ilustra una arquitectura tecnológica para sistemas de agricultura inteligente basada en la integración de sensores IoT, drones agrícolas, redes de comunicación y plataformas de almacenamiento en la nube. En este modelo, los sensores instalados en el campo recopilan información sobre variables ambientales y del suelo, como humedad, temperatura y estado del cultivo. Estos datos son transmitidos mediante redes de comunicación hacia plataformas de almacenamiento en la

nube, donde se procesan utilizando herramientas de análisis de datos y algoritmos de inteligencia artificial. Los resultados de este análisis permiten generar información estratégica que facilita la toma de decisiones en la gestión agrícola, optimizando procesos como el riego, la fertilización y el monitoreo de cultivos. Este tipo de arquitectura representa uno de los pilares tecnológicos de la agricultura digital y de la denominada Agricultura 4.0.

1.4 Gemelos digitales (Digital Twins) aplicados a la agricultura

Uno de los desarrollos más recientes dentro del ámbito de la agricultura digital es la aplicación del concepto de **gemelos digitales (digital twins)** en los sistemas agrícolas. Un gemelo digital puede definirse como una representación virtual dinámica de un sistema físico que permite simular, analizar y optimizar su comportamiento mediante el uso de datos en tiempo real (Tao et al., 2019).

En el contexto agrícola, los gemelos digitales permiten crear modelos virtuales de parcelas agrícolas, cultivos, sistemas de riego o incluso explotaciones agrícolas completas. Estos modelos digitales se alimentan continuamente de datos provenientes de sensores IoT, estaciones meteorológicas, drones y satélites, lo que permite actualizar en tiempo real el estado del sistema agrícola representado.

La principal ventaja de los gemelos digitales radica en su capacidad para simular diferentes escenarios productivos antes de que ocurran en el mundo real. Por ejemplo, los agricultores pueden utilizar estos modelos para evaluar cómo diferentes estrategias de riego, fertilización o manejo

de cultivos podrían afectar el rendimiento agrícola bajo distintas condiciones climáticas.

Asimismo, los gemelos digitales permiten anticipar posibles riesgos dentro del sistema productivo. Mediante el análisis de datos históricos y modelos predictivos basados en inteligencia artificial, es posible identificar patrones que indiquen la probabilidad de estrés hídrico, aparición de enfermedades o deficiencias nutricionales en los cultivos.

Desde una perspectiva de gestión agrícola, los gemelos digitales también facilitan la toma de decisiones basada en datos. Los agricultores pueden visualizar en tiempo real el estado de sus cultivos mediante plataformas digitales que integran información proveniente de múltiples fuentes, lo que permite adoptar estrategias de manejo más precisas y eficientes.

El uso de gemelos digitales también tiene aplicaciones importantes en el diseño de sistemas agrícolas sostenibles. Mediante simulaciones computacionales es posible evaluar el impacto ambiental de diferentes prácticas agrícolas, como el uso de fertilizantes, el consumo de agua o las emisiones de gases de efecto invernadero.

A pesar de su gran potencial, la implementación de gemelos digitales en la agricultura aún se encuentra en una fase inicial de desarrollo. La construcción de modelos digitales precisos requiere grandes volúmenes de datos de alta calidad, así como infraestructura tecnológica capaz de procesar esta información en tiempo real.

1.5 Aplicaciones de la IA en la predicción de rendimientos

La inteligencia artificial (IA) aplicada a la agricultura de precisión permite utilizar recursos como agua, fertilizantes y pesticidas de manera óptima para maximizar los rendimientos de los cultivos (Kumar et al., 2023). La IA ajusta dinámicamente aspectos como el riego basándose en predicciones meteorológicas y evalúa riesgos de plagas según las condiciones climáticas, transformando la agricultura tradicional en sistemas basados en datos y mejorando así la eficiencia y la sostenibilidad de la producción agrícola (Zhao et al., 2022).

1.5.1 Principales enfoques tecnológicos

En este apartado se revisarán las principales tendencias tecnológicas en el contexto agrícola, así como las técnicas estadísticas y de proceso que las acompañan.

Aprendizaje automático (Machine Learning)

Este enfoque incluye técnicas clásicas como la regresión lineal, Random Forest, máquinas de soporte vectorial (SVM) y el Gradient Boosting (GBDT). Estos modelos encuentran correlaciones entre variables como clima, suelo y el historial de cultivos para prever rendimientos. Liu et al. (2022) compararon los modelos Random Forest, GBDT y SVM, encontrando que el modelo LSTM (Long Short-Term Memory) ofreció un error reducido en la estimación de los rendimientos de trigo.

Deep Learning (Aprendizaje profundo)

Las redes neuronales profundas como las CNN (redes neuronales convolucionales) y LSTM (redes neuronales recurrentes) se aplican a datos complejos. Las CNN analizan imágenes satelitales o aéreas para identificar patrones vegetativos, mientras que las LSTM y GRU manejan series temporales como las tendencias climáticas. Según estudios recientes, el modelo LSTM ha demostrado un mejor rendimiento que los modelos tradicionales como Random Forest y Support Vector Regression (SVMR) al predecir el rendimiento de cultivos (Zhao et al., 2022).

Modelos híbridos

Estos modelos integran modelos agronómicos, como el APSIM (Agricultural Production Systems sIMulator), con técnicas de machine learning. Un estudio demostró que la combinación de APSIM con Random Forest mejoró significativamente la precisión de las predicciones de rendimientos en trigo, mostrando un 33% más de exactitud que el uso exclusivo de APSIM (Johnson et al., 2023).

1.5.2 IA en la optimización de procesos

Además de la predicción de rendimientos, la IA se emplea en la automatización y control de maquinaria. Por ejemplo, la cosechadora S7 de John Deere utiliza cámaras basadas en IA para estimar los rendimientos de los cultivos en tiempo real, ajustando la velocidad de cosecha, lo que aumenta la productividad hasta en un 20% (Deere, 2022).

Para que los modelos de inteligencia artificial puedan generar predicciones confiables sobre el rendimiento de los cultivos, es

necesario contar con una arquitectura de datos agrícolas que permita integrar información proveniente de múltiples fuentes. En los sistemas de agricultura inteligente, los datos son capturados mediante sensores de campo, estaciones meteorológicas, drones, imágenes satelitales y maquinaria agrícola conectada. Esta información es almacenada y procesada en plataformas de análisis basadas en computación en la nube, donde algoritmos de aprendizaje automático identifican patrones complejos entre variables climáticas, edáficas y agronómicas. La integración de estas fuentes de información permite construir modelos predictivos más robustos y adaptativos, capaces de mejorar la precisión de las estimaciones de rendimiento y apoyar la toma de decisiones basada en datos en los sistemas agrícolas modernos (Kamilaris et al., 2017; Wolfert et al., 2017; Facuy et al., 2025).

1.5.3 Ecosistema de datos agrícolas

El funcionamiento de los sistemas de inteligencia artificial aplicados a la agricultura depende en gran medida de la disponibilidad y calidad de los datos utilizados para entrenar los algoritmos predictivos. En el contexto de la agricultura digital, los datos agrícolas provienen de múltiples fuentes que forman parte de un ecosistema tecnológico interconectado.

Entre las principales fuentes de datos agrícolas se encuentran los sensores instalados en el suelo, los cuales permiten medir variables como la humedad, la temperatura, el pH y el contenido de nutrientes. Estos sensores generan datos en tiempo real que pueden ser utilizados para ajustar dinámicamente las estrategias de riego y fertilización.

Otra fuente importante de información proviene de las imágenes satelitales y los drones agrícolas. Estas tecnologías permiten monitorear grandes extensiones de terreno agrícola mediante sensores multiespectrales capaces de detectar variaciones en el estado fisiológico de los cultivos. A partir de estas imágenes es posible calcular índices de vegetación como el NDVI (Normalized Difference Vegetation Index), que permiten evaluar la salud de los cultivos y detectar situaciones de estrés hídrico o deficiencias nutricionales (Maimaitijiang et al., 2020).

La maquinaria agrícola moderna también se ha convertido en una fuente importante de generación de datos. Tractores, sembradoras y cosechadoras inteligentes están equipados con sensores que registran información sobre rendimiento del cultivo, consumo de combustible, condiciones del suelo y eficiencia operativa. Estos datos pueden ser analizados posteriormente para optimizar la planificación agrícola y mejorar la eficiencia de los procesos productivos.

La integración de todas estas fuentes de información dentro de plataformas digitales de análisis permite construir sistemas de inteligencia agrícola capaces de generar recomendaciones basadas en datos. Este enfoque representa un cambio significativo respecto a los modelos tradicionales de toma de decisiones agrícolas, que se basaban principalmente en la experiencia empírica del agricultor.

1.5.4 Tipos de datos utilizados

Los modelos predictivos de IA se nutren de datos heterogéneos provenientes de diversas fuentes. Entre los más relevantes se encuentran los datos meteorológicos (precipitación, temperatura,

humedad), imágenes satelitales y de drones (índices de vegetación como el NDVI y EVI) y datos históricos de rendimientos y prácticas de manejo agrícola (Kumar et al., 2023). Además, se incorporan parámetros edáficos (pH, nutrientes, textura del suelo) capturados por sensores IoT instalados en el campo. Estos datos permiten entrenar algoritmos de IA capaces de prever la producción de cultivos con alta precisión.

1.5.5 Ejemplos de implementación en distintas regiones

África. - El sistema Africa Agriculture Watch (AAgWa), desarrollado por AKADEMIYA2063, es una plataforma web que utiliza IA y datos satelitales para prever los rendimientos de cultivos clave como el maíz, la yuca y el sorgo en 47 países africanos. Este sistema, lanzado en 2023, proporciona a los responsables del sector agrícola acceso a análisis predictivos para enfrentar crisis climáticas y de suministro (FAO, 2023).

India. - Un proyecto piloto de ICRISAT y Microsoft en Andhra Pradesh utilizó 30 años de datos climáticos para recomendar la fecha óptima de siembra para el cultivo de maní. Los agricultores que siguieron estas recomendaciones lograron un aumento del 30% en los rendimientos promedio (ICRISAT, 2022).

Sudamérica. - En Argentina, la cosechadora John Deere S7 utiliza visión artificial para estimar la altura del cultivo y el rendimiento inminente, ajustando la velocidad de cosecha de manera automática, lo que aumenta la productividad en un 20% (Deere, 2022). En Perú, los estudios del Instituto Nacional de Innovación Agraria (INIA) han

demostrado que el uso de tecnologías basadas en IA aumentó la producción de pequeños agricultores en un 25% (INIA, 2022).

Europa. - El proyecto europeo AgriBIT combinó IA y teledetección para crear servicios de agricultura de precisión. En pruebas realizadas durante 20 meses, se detectaron infestaciones de plagas en tiempo real en cultivos de tomate, viñedo y melocotonero, lo que permitió reducir el uso de insumos como fertilizantes, pesticidas y agua, mejorando la calidad de la cosecha (AgriBIT, 2022).

1.5.6 Beneficios concretos en productividad, eficiencia y sostenibilidad

Diversos casos muestran aumentos significativos en los rendimientos, el piloto de ICRISAT y Microsoft en India logró un incremento del 30% en la producción de maní (ICRISAT, 2022). Además, la cosechadora S7 de John Deere aumentó la productividad en un 20% (Deere, 2022). Los agricultores en Brasil que utilizaron la herramienta Farmonaut mejoraron su rendimiento en soja en un 15% (Farmonaut, 2023).

La IA optimiza el uso de insumos y reduce costos un claro ejemplo es el proyecto AgriBIT qué aplicó dosis variables basadas en datos, reduciendo el uso de fertilizantes, pesticidas y agua, sin afectar los rendimientos (AgriBIT, 2022). La FAO destaca que estas tecnologías permiten una asignación más eficiente de insumos, minimizando el desperdicio de recursos como fertilizantes, mano de obra y agua (FAO, 2023).

La IA también contribuye a una agricultura más sostenible al reducir el impacto ambiental. Las tecnologías predictivas mejoran la resiliencia de los cultivos frente a eventos climáticos extremos, lo que permite una gestión más eficaz de los recursos y reduce el uso innecesario de productos químicos (Zhao et al., 2022).

En muchas regiones, la falta de un historial de datos meteorológicos y de rendimientos locales limita la precisión de los modelos de IA. Esto es especialmente problemático en áreas donde la tecnología de monitoreo no está completamente desarrollada.

Los pequeños agricultores, especialmente en países en desarrollo, pueden no tener acceso a la infraestructura digital necesaria ni a la capacitación requerida para utilizar estas tecnologías de manera efectiva (FAO, 2023).

La implementación de soluciones de IA requiere una inversión significativa en sensores, drones y almacenamiento de datos. El costo inicial puede ser un impedimento para los agricultores de pequeña escala (Johnson et al., 2023).

Los modelos deben ser ajustados a las particularidades agroclimáticas de cada región. Además, interpretar las recomendaciones de IA y generar confianza entre los agricultores sigue siendo un desafío. Es necesario establecer estándares claros y fomentar la colaboración interdisciplinaria para mejorar la calidad de los sistemas predictivos (Kumar et al., 2023).

1.6 Impacto económico de la inteligencia artificial en la agricultura

La incorporación de tecnologías basadas en inteligencia artificial y Big Data en el sector agrícola no solo tiene implicaciones tecnológicas y ambientales, sino también importantes impactos económicos en la estructura productiva del sector agroalimentario. Diversos estudios han demostrado que la digitalización agrícola puede mejorar significativamente la rentabilidad de las explotaciones agrícolas mediante la optimización del uso de insumos y la reducción de pérdidas productivas.

Tabla 1. Impactos económicos de la inteligencia artificial en la agricultura.

Área de impacto	Aplicación de IA	Beneficio económico	Evidencia reportada
Gestión del riego	Algoritmos predictivos de humedad	Reducción del consumo de agua	30–50% menos agua
Fertilización	Dosificación variable	Reducción de insumos	Hasta 25% menos fertilizantes
Control de plagas	Visión artificial y drones	Menor uso de pesticidas	Reducción de hasta 90%
Predicción de rendimiento	Modelos de machine learning	Mejor planificación agrícola	Aumento de rendimiento 10–30%
Gestión de maquinaria	Mantenimiento predictivo	Reducción de costos operativos	Ahorro del 20%

Nota. Elaboración propia con base en Kumar et al. (2023), Basso y Antle (2020), y Singh et al. (2022).

Uno de los principales beneficios económicos de la inteligencia artificial en la agricultura es la reducción de costos operativos asociados al uso de recursos como agua, fertilizantes y pesticidas. Los sistemas de agricultura de precisión permiten aplicar estos insumos únicamente en las áreas del cultivo que realmente lo requieren, evitando el desperdicio de recursos y reduciendo los costos de producción (Kumar et al., 2023).

Además, la inteligencia artificial permite mejorar la planificación agrícola mediante la predicción de rendimientos y la identificación temprana de riesgos climáticos o fitosanitarios. Esto permite a los agricultores tomar decisiones más informadas sobre la selección de cultivos, el calendario de siembra y las estrategias de manejo agronómico.

Otro aspecto relevante es el desarrollo de nuevos modelos de negocio dentro del ecosistema tecnológico agrícola. Empresas especializadas en análisis de datos agrícolas, desarrollo de sensores inteligentes y plataformas de gestión agrícola han surgido como actores clave en la transformación digital del sector agroalimentario.

1.7 Optimización de recursos mediante Inteligencia Artificial en la Agricultura

La optimización de recursos es una de las principales ventajas que ofrece la inteligencia artificial (IA) en el sector agrícola. A través del análisis de grandes volúmenes de datos (Big Data), los algoritmos de

IA permiten un uso más eficiente y preciso de recursos como el agua, fertilizantes, pesticidas, energía y mano de obra. Esto se traduce en una reducción de costos operativos, minimización del impacto ambiental y mejora en la sostenibilidad del sistema productivo (Kumar et al., 2023).

Este enfoque basado en datos también ha sido aplicado en modelos de predicción ambiental y gestión sostenible de recursos mediante técnicas avanzadas de aprendizaje automático (Facuy et al., 2025).

Tabla 2. Aplicaciones de la inteligencia artificial para la optimización de recursos en la agricultura.

Tecnología basada en IA	Recurso optimizado	Aplicación agrícola	Beneficio principal
Sensores IoT y monitoreo inteligente	Agua	Medición de humedad del suelo y control automático del riego	Reducción del consumo de agua hasta 50%
Visión artificial con drones	Pesticidas	Identificación temprana de plagas y enfermedades	Aplicación focalizada de agroquímicos
Sistemas de recomendación basados en IA	Fertilizantes	Dosificación variable según necesidades del cultivo	Reducción del uso de fertilizantes
Algoritmos predicción climática	Energía y logística	Optimización del uso de maquinaria y planificación agrícola	Reducción de costos operativos

Plataformas d agricultura de precisión	Recursos integrados	Análisis espacial del rendimiento del cultivo	Mejora de la eficiencia productiva

***Nota*.** Elaboración propia con base en Kumar et al. (2023), Zhao et al. (2022) y FAO (2023).

Como se observa en la Tabla 2, las tecnologías basadas en inteligencia artificial permiten optimizar diversos recursos dentro del sistema productivo agrícola. La integración de sensores, algoritmos predictivos y plataformas de análisis de datos facilita una gestión más eficiente de insumos críticos como el agua, los fertilizantes y los pesticidas, contribuyendo simultáneamente a mejorar la productividad y a reducir el impacto ambiental de la actividad agrícola.

1.7.1 Principales estrategias tecnológicas

El auge de las tecnologías ha llegado a revolucionar el sector productivo agrícola, siendo este un engranaje clave para la supervivencia humana, puesto que es el área que genera alimentos y tributa al objetivo dos de los Objetivos de Desarrollo Sostenible “hambre cero”. Los accesos a las tecnologías han ido insertándose paulatinamente, puesto que han existido algunas brechas que superar previamente, como lo es la conectividad en las áreas rurales, la capacitación del agricultor y romper los paradigmas del agroempresario al sacarlo de su zona de confort. En este contexto, se describe a continuación las tecnologías emergentes.

Agricultura de precisión basada en IA

La agricultura de precisión utiliza sensores, imágenes satelitales, drones e IoT para monitorear parámetros clave del suelo, las plantas y el clima. Los algoritmos de IA procesan esta información en tiempo real para ofrecer recomendaciones personalizadas sobre cuándo, dónde y cuánto aplicar de cada recurso. Esta toma de decisiones localizada maximiza la eficiencia en el uso de insumos y reduce significativamente el desperdicio (Zhao et al., 2022).

Por ejemplo, sistemas como FieldView de Climate Corporation emplean modelos predictivos para indicar zonas específicas del terreno donde se debe intensificar el riego o aplicar fertilizantes. Se ha reportado que el uso de esta herramienta ha permitido reducir el uso de nitrógeno en un 25% sin comprometer el rendimiento de los cultivos (Climate Corporation, 2022).

Riego inteligente

Los sistemas de riego automatizado controlados por IA analizan la humedad del suelo, las condiciones climáticas futuras y las características del cultivo para determinar el volumen y la frecuencia de riego óptimos. Según un estudio realizado por Singh et al. (2022), estos sistemas pueden reducir el consumo de agua entre un 30% y un 50%, comparado con métodos tradicionales de riego, especialmente en cultivos como tomate, maíz y arroz.

Un ejemplo concreto es el sistema Plantix, que, mediante sensores conectados a la nube, monitorea la humedad del suelo en tiempo real y activa el riego únicamente cuando es necesario, evitando el exceso o déficit hídrico.

Aplicación eficiente de fertilizantes y pesticidas

Mediante visión artificial e imágenes multiespectrales, la IA puede detectar la presencia de plagas, enfermedades o deficiencias nutricionales en etapas tempranas. Esto permite realizar aplicaciones focalizadas de pesticidas o fertilizantes únicamente en las zonas afectadas, en lugar de tratar todo el campo de forma generalizada (Liu et al., 2022).

En pruebas de campo, la empresa Blue River Technology, filial de John Deere, ha implementado el sistema See & Spray, que identifica malezas de forma individual en tiempo real y aplica herbicida solo donde es necesario. Esto ha permitido reducir el uso de agroquímicos en un 90% en cultivos de soja y algodón (Blue River Technology, 2022).

Logística y gestión de maquinaria agrícola

La IA también optimiza la logística y el uso de maquinaria en tiempo real. Algoritmos de planificación basados en redes neuronales pueden generar rutas más eficientes para tractores y cosechadoras, reduciendo el consumo de combustible y el tiempo operativo (Deere, 2022). Además, la recolección de datos en campo permite programar mantenimientos predictivos, lo que evita fallos costosos y mejora la vida útil de los equipos.

1.7.2 Beneficios cuantificables

- Reducción del consumo de agua: Hasta un 50% mediante sistemas de riego inteligente basados en IA (Singh et al., 2022).

- Reducción del uso de agroquímicos: Entre un 60% y 90% al aplicar pesticidas de manera focalizada (Blue River Technology, 2022).

- Disminución de costos operativos: Estudios realizados en Chile y Brasil reportan reducciones del 20% al 35% en los costos de producción gracias a la IA (FAO, 2023).

- Mejora en la sostenibilidad: La FAO (2023) señala que los sistemas inteligentes de monitoreo y aplicación permiten conservar los recursos naturales, mejorar la biodiversidad y mitigar el cambio climático.

Aunque los beneficios de la optimización de recursos con IA son evidentes, su adopción enfrenta desafíos. Entre ellos, destacan la necesidad de conectividad rural, el alto costo inicial de los equipos inteligentes, la resistencia al cambio por parte de los agricultores tradicionales y la necesidad de formación técnica (Kumar et al., 2023). Superar estos retos implica políticas públicas inclusivas, financiamiento agrícola e incentivos para la innovación tecnológica.

1.8 Control de plagas mediante Inteligencia Artificial en la Agricultura

El control de plagas representa uno de los mayores desafíos para la productividad agrícola y la seguridad alimentaria. Según datos de la FAO (2022), se estima que hasta el 40% de los cultivos a nivel mundial se pierden anualmente a causa de plagas y enfermedades. En este contexto, la inteligencia artificial (IA) ha emergido como una

herramienta clave para transformar las estrategias tradicionales de manejo, permitiendo una detección más temprana, una respuesta más precisa y una reducción significativa en el uso de pesticidas químicos.

1.8.1 Modelos predictivos para el control de plagas y enfermedades

El control de plagas y enfermedades constituye una de las prioridades más apremiantes en la agricultura, ya que las pérdidas ocasionadas por estos factores pueden comprometer significativamente la seguridad alimentaria y la estabilidad económica de los productores. La Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2019) estima que hasta un 40% de los cultivos a nivel mundial se pierden anualmente debido a plagas, lo que se traduce no solo en pérdidas económicas, sino también en afectaciones al acceso y calidad de los alimentos. En este contexto, los modelos predictivos basados en Big Data y herramientas de inteligencia artificial han adquirido relevancia estratégica, al permitir anticipar la ocurrencia de brotes y facilitar intervenciones más eficaces, específicas y sostenibles.

Estos modelos se construyen a partir del procesamiento de grandes volúmenes de datos provenientes de múltiples fuentes, como sensores de campo, estaciones meteorológicas, imágenes satelitales, históricos de incidencia de plagas, condiciones edafoclimáticas y características genéticas de los cultivos. A través del uso de algoritmos avanzados, como las redes neuronales artificiales, los árboles de decisión o las máquinas de vectores de soporte, se logra identificar patrones y correlaciones que no serían evidentes mediante métodos tradicionales. Esta capacidad analítica permite predecir con alto grado de precisión

las condiciones propicias para la aparición y propagación de plagas o enfermedades, contribuyendo a una agricultura más resiliente frente al cambio climático y a las variaciones microambientales (Mahlein et al., 2018).

Un ejemplo ilustrativo se encuentra en el manejo del mildiu en la vid, causado por el patógeno *Plasmopara viticola*. Investigaciones recientes han demostrado que es posible desarrollar modelos predictivos que integran variables como la temperatura, la humedad relativa, la fenología del cultivo y antecedentes históricos de brotes, logrando anticipar la probabilidad de aparición de la enfermedad con varios días de antelación. Esto permite planificar las medidas de control en momentos estratégicos, reduciendo el uso innecesario de fungicidas y evitando la pérdida de cosechas (Bock et al., 2020).

El potencial de estos modelos va más allá de la predicción, al integrarse con sistemas de alerta temprana y plataformas de gestión agrícola digital. Herramientas como *iPiPE* (Integrated Pest Information Platform for Extension and Education) en Estados Unidos permiten recopilar datos en tiempo real mediante aplicaciones móviles utilizadas por agricultores, técnicos y especialistas, generando mapas dinámicos de riesgo fitosanitario. Estas plataformas, al cruzar la información georreferenciada con modelos climáticos, logran emitir alertas oportunas y recomendaciones personalizadas sobre el uso racional de agroquímicos y el monitoreo de focos de infestación (Nelson et al., 2017).

Asimismo, el uso de modelos predictivos tiene un impacto directo en la sostenibilidad agrícola. La reducción del uso de pesticidas no solo disminuye los costos de producción, sino que también mitiga los efectos negativos sobre los recursos naturales, la biodiversidad y la salud humana. En países como los Países Bajos, estudios aplicados en cultivos de papa han demostrado que la implementación de modelos predictivos permitió reducir hasta un 30% el número de aplicaciones de fungicidas sin comprometer el rendimiento ni la calidad del producto, promoviendo una agricultura más limpia y eficiente (Pieters et al., 2021).

La incorporación de estos modelos en plataformas inteligentes como *FieldView*, *Agremo* o *FarmShots* también ha transformado la forma en que los agricultores toman decisiones. Estas soluciones tecnológicas permiten recibir notificaciones automáticas sobre amenazas fitosanitarias potenciales, con base en el análisis de imágenes satelitales, sensores de humedad y temperatura, y modelos de predicción climática. El acceso a esta información, en tiempo real y desde dispositivos móviles, brinda al agricultor la posibilidad de actuar con rapidez y precisión, optimizando recursos y reduciendo las pérdidas.

En definitiva, los modelos predictivos aplicados al control de plagas y enfermedades representan una herramienta de vanguardia en la transformación digital del sector agropecuario. Al facilitar un manejo más anticipado, personalizado y ecológicamente responsable de las amenazas fitosanitarias, contribuyen a consolidar sistemas agrícolas más resilientes, productivos y sostenibles. Su implementación,

combinada con políticas públicas de apoyo a la innovación y la capacitación técnica de los agricultores, será clave para enfrentar los desafíos futuros de la producción alimentaria en un entorno de creciente incertidumbre climática y demanda global.

1.8.2 Detección temprana y diagnóstico automatizado

Una de las principales contribuciones de la IA al control de plagas es su capacidad para detectar signos de infestación o enfermedad antes de que sean visibles a simple vista. Mediante técnicas de visión por computadora, redes neuronales convolucionales (CNN) y análisis automatizado de imágenes, los algoritmos pueden identificar patrones característicos de ataques por insectos, hongos o virus (Ferentinos, 2018; Mohanty et al., 2016; Facuy-Delgado et al., 2022).

Por ejemplo, aplicaciones como **Plantix** o **Agremo** permiten que los agricultores tomen una foto de una planta con síntomas visibles, y el sistema entrenado con miles de imágenes diagnostica el tipo de plaga o enfermedad, su nivel de severidad y sugiere medidas de control. Estos modelos alcanzan precisiones superiores al 90% en cultivos como tomate, papa, maíz y arroz (Mohanty et al., 2016).

1.8.3 Visión artificial y redes neuronales convolucionales para el diagnóstico

La visión por computadoras es un área de las ciencias de la computación que ha ganado suma importancia en la solución de problemas, gracias al desarrollo hardware de las tarjetas gráficas (GPU) y su

abaratamiento. En este contexto la IA hace sus aportes con algoritmos como las redes neuronales y se analizarán a continuación:

1.8.4 Fundamentos de las redes neuronales convolucionales

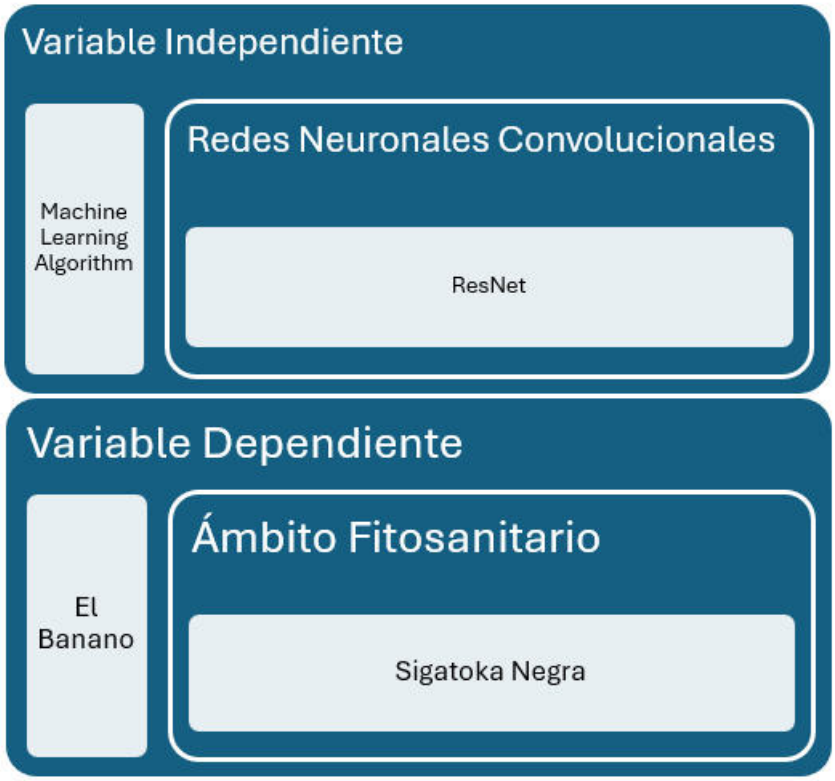


Figura 2. Red de categorías de las variables de investigación.

Las Redes Neuronales Convolucionales es una arquitectura de red neuronal profunda que puede ser utilizada en el aprendizaje profundo, y este a su vez al aprendizaje automático. Es la Red Neuronal Profunda más utilizada (ver Figura 2) (Sharma y otros, 2020) desde el 2012 (Jiang & Li, 2020). Esta consiste en capas de neuronas en que la red utiliza la convolución de operaciones matemáticas en al menos una de las capas dentro de la matriz (Sharma y otros, 2020). El objetivo de la capa de

convolución es extraer características de la imagen de entrada, para luego aplicarse varios filtros de aprendizaje, utilizando los canales de colores RGB procesa y genera un mapa de características. (Amara y otros, 2017)

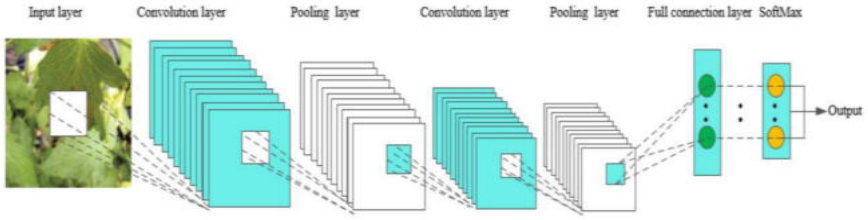


Figura 3. Estructura básica de Redes Neuronales Convolucionales.

Nota. Tomado de los autores *Liu y Wang, 2021.*

En la Figura 3 podemos apreciar una estructura básica de la red (Liu & Xuewei, 2021). Además, se aprecia un clasificador de imágenes supervisado denominado Softmax, donde los conjuntos de datos son etiquetados para entrenar el algoritmo (Ahmad y otros, 2026).

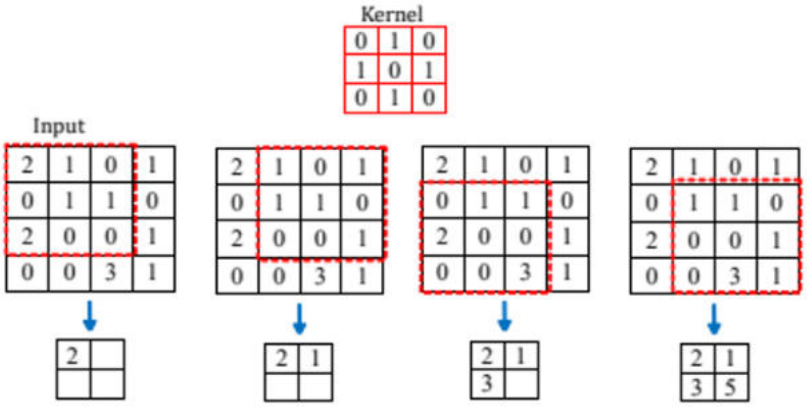


Figura 4. Ejemplo de convolución con una imagen de entrada de 4x4 y un kernel de 3x3. Naranjo-Torres y otros. 2020.

Como se puede apreciar en la Figura 4, un filtro opera de izquierda a derecha y luego de arriba abajo en la imagen. En cada celda se calcula la suma de los productos entre cada elemento del Kernel y el elemento de entrada que corresponde. Este proceso puede realizarse usando diferentes Kernels como mapas de características de salida se necesite (Naranjo-Torres y otros, 2020).

Las principales arquitecturas de Redes Neuronales Convolucionales más utilizadas son AlexNet, ZFNet, VGGNet, Inception Family, Resnet Family, DenseNet, NasNet, RCNN Family, YOLO Family, SSD, RetinaNet, FCN, U-Net, DeepLab Family y Mask RCNN (Jiang & Li, 2020).

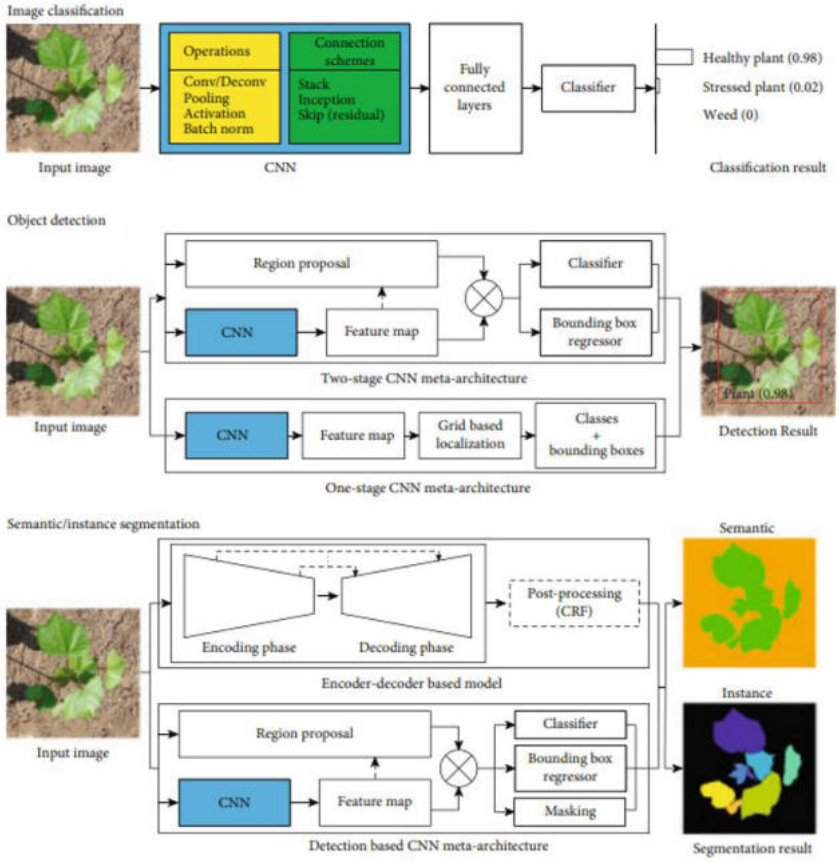


Figura 5. Diagrama de Arquitectura CNN en cada una de sus fases. Jiang y Li, 2020.

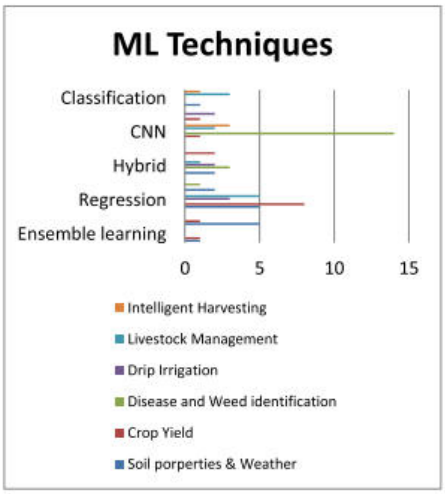


Figura 6. Tecnicas de Machine Learning utilizadas en la agricultura de precisión. Sharma y otros, 2021.

Entre las principales categorías que se han encontrado estudios de Redes Neuronales están analizar el estrés de las plantas, desarrollo de las plantas, calidad de la postcosecha. En el desarrollo de las plantas está control de crecimiento, morfología de las hojas y conteo de hojas. En la postcosecha el análisis de la composición química (pudrición) y detección de defectos en la fruta (Jiang & Li, 2020).

Pytorch

Esta es una herramienta de Deep Learning, publicada por Facebook. Soporta hardware CPU, GPU y FPGA. Puede trabajarse con las interfaces de C, Python o Lua. Es fácil para depurar y desarrollar, soporta Redes Neuronales, es fácil para expandir y modularizar, así como de bajo costo de aprendizaje (Liu & Xuewei, 2021).

ResNet y aprendizaje por transferencia

La familia ResNet fue concebida como una red profunda para el tratamiento de imágenes y posteriormente se la ha utilizado como backbone de características en tareas de visión artificial para clasificar imágenes, su popularidad empezó desde el 2015. Posee una representación residual y esquema de conexión de salto que permite el entrenamiento de redes convolucionales muy profundas[1] (Jiang & Li, 2020).

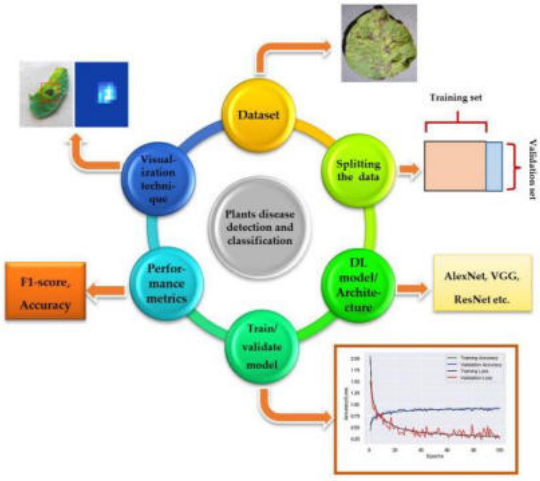


Figura 7. Diagrama de Flujo de una implementación de Aprendizaje Profundo utilizando CNN. Saleem, Potgieter y Arif, 2019.

En la Figura 7 se puede apreciar un diagrama de flujo tradicional para clasificar imágenes con enfermedades de plantas, y entrar en contexto.

[1] https://github.com/TensorFlow/models/tree/ master/official/resnet (TensorFlow) https://github.com/pytorch/vision/blob/master/ torchvision/models/resnet.py (PyTorch)

En el círculo de DL mode/Architecture podemos apreciar que es la fase en la que se puede usar ResNet. (Saleem y otros, 2019).

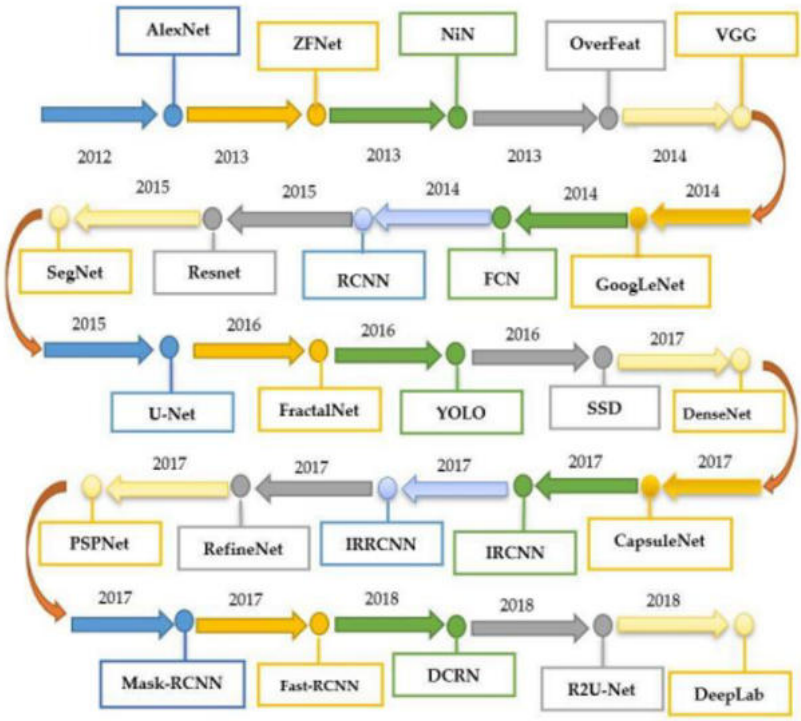


Figura 8. Evolución histórica de varios modelos desde 2012. Saleem, Potgieter y Arif, 2019.

Como podemos apreciar en la Figura 8, ResNet arranca desde el año 2015, con 25.5 M parámetros. Tiene mejor precisión que el modelo VGG y GoogLeNet (Saleem y otros, 2019).

1.8.5 Aplicaciones de CNN en la detección de enfermedades agrícolas

Entre los principales usos se encuentran; Predicción de propiedades del suelo y condiciones climáticas, determinar campos de cultivo en especial para arroz, café y maíz, detección de malezas, cría de ganado

y riego por goteo (Sharma y otros, 2020); y Detección de enfermedades en plantaciones de olivo (Saleem y otros, 2019).

Un estudio con Redes Neuronales Convolucionales sirvió para 14 cultivos y 26 enfermedades, el Dataset utilizado fue PlantVillage, el framework pyTorch, y obtuvo una precisión del 99.76%. Se considera que los modelos con más precisión son DenseNet201, VGG16 y Resnet (Ngugi y otros, 2021).

En otro estudio, con el cultivo de yuca logró una eficiencia del 93%, los autores usaron un Dataset de dominio público y lo entrenaron usando la arquitectura AlexNet y GoogleNet para identificar 26 enfermedades en 14 tipos de cuerpos, se logró una precisión de identificación de las enfermedades en un 99.35% de los casos. Algo importante a recalcar es que las imágenes fueron realizadas bajo las condiciones de laboratorio (Escudero y otros, 2022).

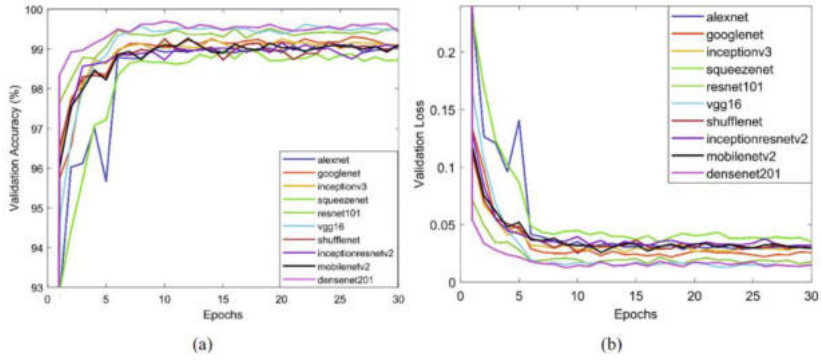


Figura 9. Estadística de uso de las redes.

Nota. (a) precisión de la validación y (b) perdida de validación de 10 arquitecturas de Redes Neuronales Convolucionales Ngugi, Albewahab y Abo-Zahad, 2020.

En la Figura 9 podemos notar que ResNet está entre las tres redes más precisas en su validación y las más bajas en perdida de validación usando teléfonos móviles y aplicaciones embebidas; las otras son Net201 e Inceptionv3. Razón por la cual se utilizó ResNet en la presente investigación. Específicamente obtuvo en precisión 0.9951, precisión 0.9924, recall 0.9936, especificidad 0.9999 y F1 Score 0.9929 (Ngugi y otros, 2021).

En los inicios (2015) las redes neuronales se usaban para clasificar y detectar. Luego en el 2017 se popularizo en la detección, en el 2018 hubo auge en la clasificación y actualmente la tendencia de uso es para los sistemas de detección de alerta temprana de plagas y enfermedades (Naranjo-Torres y otros, 2020).

Aplicaciones de CNN en el cultivo de banano

En cuanto a la utilización de las redes convolucionales en el cultivo del banano; Escudero, Calvo y Bejarano en el 2022 (Escudero y otros, 2022) utilizan la Red Convolucional LENET con tamaños de imagen de 96x96, para detectar Sigatoka Negra. Se utilizó su propia base de datos de hojas enfermas, pues no encontraron bases de datos de libre acceso. Se comparó con los clasificadores Inception-v3 y Suport Vector Machine, obteniendo los siguientes resultados:

Tabla 3. Comparación de clasificadores.

Dificultad	CNN LeNet	CNN Inception-v3	Support Vector Machine
High	87% ± 2.1%	92.16% ± 2.4%	80% ± 3.1%
Medium	80% ± 1.9%	13.29% ± 1.4%	83% ± 2.4%
Low	99% ± 1.7%	70.77% ± 2.0%	94% ± 2.5%
Total	90.03% ± 1.7%	74.51% ± 1.9%	86.16% ± 2%

Nota. Tabla elaborada en base al artículo de Facuy y otros (2025)

Existe un estudio para banano que utiliza la arquitectura de entrenamiento LeNet con modelos RGB y GRAY. Lograron detectar las enfermedades en un 98% de las veces. Consideran que uno de los principales retos es las condiciones ambientales para capturar la imagen. (Escudero y otros, 2022)

Las Redes Neuronales también se han utilizado para determinar el grado o fases de madurez del banano, bajo condiciones de laboratorio. Se utilizaron 17312 imágenes. Y se logró determinar cual es el grado y si están o no aptos para la comercialización. Se utilizó una capa Fully Coneccted con 512 neuronas y se combinó con una Unidad de Rectificación Linear (ReLU). La precisión fue de 94.4% y de perdida 0.15% (Yan Zhang y otros, 2018).

Con una base de datos de imágenes de África e India se utilizaron tres arquitecturas de redes convolucionales para detectar enfermedades y pestes en el banano. Se desarrollaron seis diferentes modelos de 18 diferentes clases. El estudió encontró que el mejor desempeño se encuentra utilizando los modelos ResNet50 y InceptionV2 comparado con MobileNetV1 (Gomez Selvaraj y otros, 2019).

Según una revisión sistémica de Saleem, Potgier y Arif hasta el año 2019 se encontraron 101 artículos científicos que utilizaron ResNet, para dar soluciones tecnológicas en el cultivo de tomate, manzanas, naranjas, maíz entre otros productos. Se considera que se pueden aplicar las mismas estrategias para otros cultivos. Sin embargo, hasta el 2019 no existían trabajos para el banano (Saleem y otros, 2019).

Un trabajo interesante es el de Gomez Selvaraj y otros (Gomez Selvaraj y otros, 2020) el cual por medio de satélites (Sentinel 2, PlanetScope y WorldVIew2) detecta las plantas de banano y su estado de salud. La arquitectura utilizada fue RetinaNet y se Obtuvo una precisión del 97%. Esto abre la posibilidad de trabajar con drones.

En el año 2023 en Bangladesh se trabajó con cuatro arquitecturas de Redes Convolucionales (Resnet-50, Inception-V3, VGG-16 y BananaSqueezeNet) afinando las arquitecturas con optimización Bayesiana. Como aporte de esta investigación queda BananaSqueezeNet la cual es una arquitectura diseñada por los autores. El objetivo del trabajo consiste en identificar si la planta tiene una de las tres enfermedades en la hoja: Cordana, Sigatoka, Pestalotiopsis. No identifica estadios o fases en que se encuentra la enfermedad, solo identifica cuál tiene. De las cuatro arquitecturas la que produjo más exactitud (96.25%) fue BananaSqueezeNet. (Bhuiyan y otros, 2023)

Los presentes estudios evidencian que las CNN están siendo utilizadas tanto a la identificación de enfermedades como a la clasificación del estado del banano. Por lo tanto, resulta pertinente examinar un caso

experimental orientado específicamente a la clasificación de la severidad (estadios) de la Sigatoka Negra.

1.8.6 Monitoreo continuo con drones e IoT

Los drones equipados con cámaras térmicas e hiperespectrales pueden sobrevolar campos agrícolas y recolectar datos sobre el estado fitosanitario del cultivo. La IA analiza en tiempo real estos datos para identificar zonas con probabilidad alta de infestación, generando mapas de calor que permiten focalizar el control (Zhou et al., 2020).

Del mismo modo, dispositivos IoT instalados en el campo como trampas inteligentes o estaciones meteorológicas recopilan datos sobre humedad, temperatura y presencia de insectos. Estos datos se envían a plataformas en la nube donde algoritmos predictivos advierten posibles brotes, alertando a los agricultores antes de que se generalice el problema (Ramesh et al., 2022).

1.8.7 Caso aplicado: reconocimiento de Sigatoka Negra en banano mediante Deep Learning

El auge de la inteligencia artificial está presente en la mayoría de las actividades agrícolas, como automatizaciones de riego, selección de semillas, recomendadores de gestión, y dentro de estas cuestiones el ámbito fitosanitario. Las enfermedades agrícolas son bastante complejas, pues para su proliferación interfieren un sin número de variables, entre ellas, el clima, la temperatura, la estación del año e incluso la proximidad de infecciones entre fincas.

Para determinar el nivel de enfermedad de una planta de banano, es necesario acudir al juicio profesional de un experto en cuestiones fitosanitarias, esto desde ahí, ya significa una limitante, puesto que los asesores profesionales usualmente tienen altos honorarios o pertenecen a una multinacional que brinda la asesoría integral incluyendo el tratamiento; con lo cual, los pequeños productores al tener dificultades financieras, suelen dejar que la plantación llegue a estadios críticos antes de tomar una decisión en etapas tempranas.

Es por este motivo, que una iniciativa tecnológica es contribuir a que el agricultor dotado con su teléfono celular pueda tener un diagnóstico temprano de la identificación del avance de la sigatoka negra, todo esto con la finalidad de tomar decisiones en cuanto a su cuidado.

1.8.8 Contexto fitosanitario del banano y la Sigatoka Negra



Figura 10. Banano en cajas para exportación (destino).

El banano es una fruta que se da en climas tropicales, en especial en países que están más cerca de la línea ecuatorial, por la asimilación de azúcares gracias los rayos del sol. Es de las frutas frescas más

exportadas por su valor y volumen. Su cultivo es perenne y puede cultivarse durante todo el año. Es de suma importancia para los países en vías de desarrollo como los centroamericanos, Ecuador, Colombia, Honduras, Guatemala, Filipinas entre otros. Suele ser cultivado para abastecer el consumo interno, existiendo variedades que son más sabrosas pero delicadas para exportar como el "guineo seda" u "oritos", pero para exportar la variedad por excelencia es Cavendish. También se la categoriza como banana para cocción y para postres o dulces. Se estima que las exportaciones crecen en un 5.3% anual considerándose un producto clave para la seguridad alimentaria mundial pues se estima que el 85% de su producción proviene de pequeños agricultores (FAO, 2000).

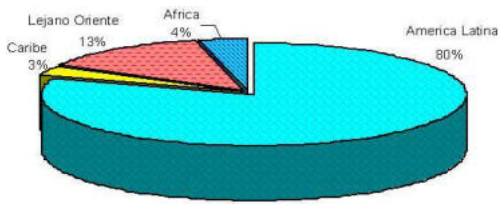


Figura 11. Bananos para postre: Exportación por continente desde el 1998 hasta el 2000.

Nota. Fuente FAOSTAT

La Sigatoka Negra

Sigatoka negra (Mycosphaerella fijiensis), es la enfermedad de mayor importancia en el cultivo de musáceas; disminuye el área foliar en las plantas, su control es con fungicidas a través de aplicaciones aéreas. El manejo de la Sigatoka Negra, depende de dos factores: el monitoreo y

la rotación de los grupos químicos: DMIs, QoIs, APs, SDHI, guanidinas, N-fenilcarbamatos y multisitios. (Churchill, 2011)



Figura 12. Estadios de evolución de la Sigatoka Negra.

Nota. Fuente: Alvarado-Capo y otros, 2003

La Sigatoka es un hongo que se propaga por el aire, razón por la cual sus síntomas son desde la parte alta de la planta (Leiva-Mora y otros, 2010). Depende del clima y por ende de la humedad del terreno para aumentar su propagación. Si no se detecta en un estadio 3 (Ver Figura 13) se corre el peligro que la planta sufra daños irreversibles que afecten al ciclo de producción. Existen fórmulas para determinar la cantidad de producción en base al número de hojas; en todo el ciclo de vida de la planta son hasta 45 hojas y lo ideal es tener de 8 a 12 hojas. Finalmente, la enfermedad también ocasiona maduración temprana, lo cual afecta al mercadeo (Churchill, 2011).



Figura 13. Ciclo patológico de la Sigatoka Negra.

Fuente: Tomado de http://www.fao.org/3/as089s/as089s.pdf. 2021

Lo ideal para el control eficiente es el detectarla de forma temprana en el estado 3 (Ver figura 14). Por medio de un Promedio Ponderado de Infección (PPI), donde si la hoja está afectada en más de un 50% se deben tomar medidas drásticas para la mejora, como aumento de la dosis al fumigar vía aérea. Este promedio se recomienda tomando una muestra de mínimo 3 plantas en un Pogo (area desde 8 mtrs. a 12,5 mtrs que pertenece a un lote). Una hoja clave en el proceso es la denominada hoja candela u hoja más joven, pues analizando el estadio en que se encuentra la enfermedad se toman decisiones.

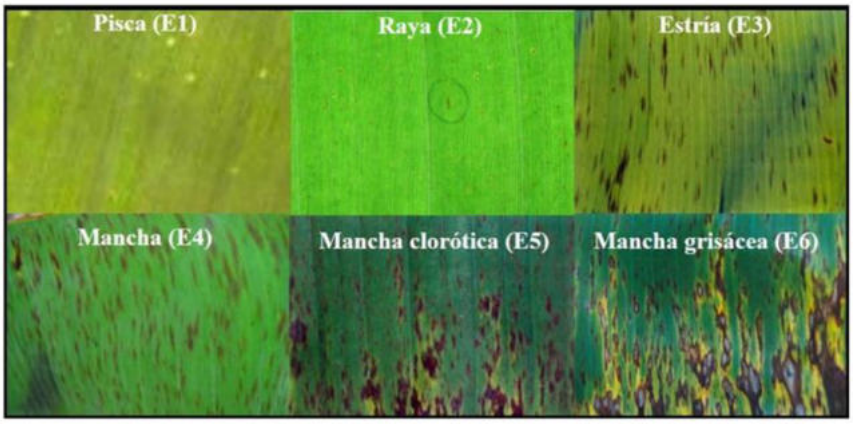


Figura 14. Escala o estadios de la Sigatoka Negra según Fouré (1985).

Entre las actividades que se realizan para controlar la enfermedad están:

- Deshoje / Deshoje con cirugía (Para lo cual se utiliza personal de campo/jornalero)
- Tratamiento fitosanitario / Fumigación aérea (Técnico agrícola)

En cuanto al tratamiento técnico, se contacta con el fitosanitario de confianza para que determine la dosificación. Este tratamiento puede ser sistémico (recomendado pues penetra el tejido de la hoja, pero se deben alternar porque desarrolla resistencia al químico), suspensión o contacto (preventivo), emulsión, y orgánico. Generalmente se aplica aceite fungistático con agua y sulfatantes.

- Coronar planta / deshijar

Trabajo con personal de campo/jornalero capacitado. Las enfermedades que tienen ciertos parecidos son “La Roya” y “Piricularia”. Además de problemas de virosis, nutrición o insectos.

- Mejora del sistema de drenajes

La idea es reducir la humedad de la planta, lo cual es el caldo de cultivo para el hongo.

- Análisis de nutrientes

En especial del potasio, el cual tiene una relación directa con el desarrollo del mal.

Tabla 4. Escala de los grados de afectación o estadios.

Grado de afectación	**Descripción**
0	Predominio de hojas sanas
1	Predominio de hojas con pequeñas lesiones puntiformes de coloración rojiza
2	Predominio de hojas con manchas de contornos irregulares o regulares de coloración rojiza por el envés de las hojas
3	Predominio de hojas con manchas de contornos irregulares o regulares de coloración pardo-rojiza por el haz.
4	Predominio de hojas con manchas negras (elípticas o redondeadas), con bordes cloróticos y halo acuoso y la presencia de sectores verdes
5	Predominio de hojas con manchas negras con centros grises; las hojas pueden colgar del pseudotallo
Clasificación de los genotipos de acuerdo al grado de afectación	
Clasificación	**Estados**
Resistentes	Estados 0–1
Parcialmente resistentes	Estados 2–3
Susceptibles	Estados 4–5

Nota. Realizado en base a Alvarado et al. (2003)

El problema del diagnóstico de la severidad en campo

El Banano en Ecuador y el mundo

El sector agrícola es una importante industria a nivel mundial pues contribuye a mejorar las condiciones económicas de la mayor cantidad de personas, siendo reflejado en el aporte a los Objetivos de Desarrollo Sostenible (ODS); 1 "fin de la pobreza" y 2 "Hambre Cero" . El banano a nivel mundial es el cuarto producto alimentario, detrás del arroz, trigo y maíz. Siendo uno de los principales productos cultivados en los países en vía de desarrollo; es una de las frutas de mayor consumo a nivel mundial con un 16% (Yan Zhang y otros, 2018).

En Ecuador el cultivo de banano se constituye en el principal producto de exportación; ocupando el 29% del mercado mundial[2] , siendo una de las fuentes de ingresos más importantes para los pequeños agricultores (aporta 3.84 al PIB ecuatoriano según su Ministerio de Economía).

Retos y complejidades[3]

- No se puede dar un tratamiento uniforme a una parcela pues el avance de la enfermedad es de acuerdo a lotes de terreno. Los lotes establecen los administradores de la parcela en base a características en común como altura del terreno, linderos, facilidades de drenaje, vías de acceso.

[2] https://www.fao.org/3/y5102s/y5102s04.htm#TopOfPag
[3] Información resultante de entrevista al Ph. D. Abrahan Rodolfo Cervantes de la UTMACH

- Las entrevistas exploratorias identificaron falencias en el registro adecuado y sistémico de información productiva y una alta dependencia de las recomendaciones proporcionadas por servicios fitosanitarios externos, que generalmente provienen de las empresas que monopolizan el sector.
- Si se trata el hongo dentro de las 48-72 horas de ovulación no forma esporas volátiles.
- Si el tratamiento es sistémico este debe ser alternado porque genera resistencias. No debe aplicarse más de 3 veces al año.
- Si las exportadoras se enteran de brotes de Sigatoka afectaría la compra al productor.
- Al aplicar tratamiento fitosanitario es importante considerar cuestiones climáticas.

Construcción y etiquetado de la base de imágenes

Tamaño de las imágenes

Generalmente, el estado del arte las redes neuronales usadas para reconocimiento de imágenes (Krizhevsky y otros, 2017) trabajan con imágenes de tamaños pequeños (típicamente 224 × 224), esto debido principalmente a que esto permite ahorrar cómputo y memoria de GPU, ya que los feature maps producidos internamente en la red neuronal también serán pequeños. Sin embargo, en el problema planteado, las manchas de la enfermedad Sigatoka a menudo son pequeñas en relación al tamaño de la hoja, por lo que al redimensionar la imagen pueden perderse detalles importantes.

Experimentos

En esta sección se describen los resultados obtenidos al entrenar el modelo propuesto con la base de datos de imágenes recolectadas. Para evaluar su desempeño, se analizan las curvas de pérdida y validación, así como la matriz de confusión. Además, se presentan los resultados obtenidos con dos variantes del modelo: la primera entrenada con tres escalas de la enfermedad y la segunda, solo con dos escalas.

Base de datos y etiquetado

La base de datos se recolectó en dos salidas de campo, en días distintos cada una. En total se capturaron 201 imágenes[4] que se organizaron en 6 carpetas cuyos nombres corresponden al grado de enfermedad de las imágenes (0, 1, 2, 3, 4 y 5). A continuación, se muestran algunos ejemplos de imágenes para cada escala:

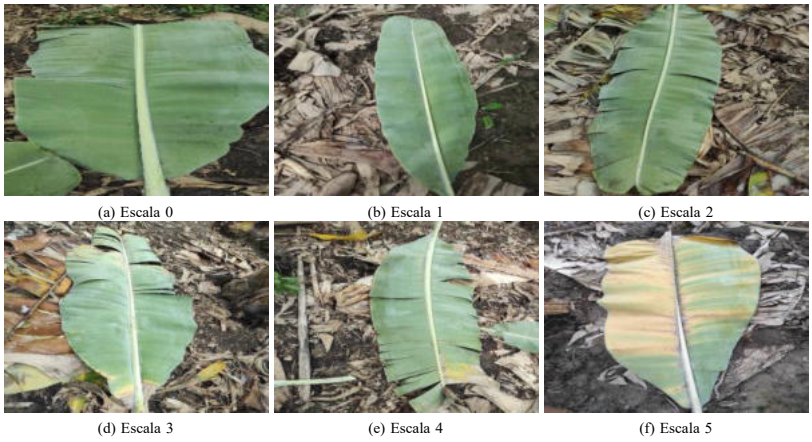


Figura 15. Ejemplo de imágenes capturadas para cada una de las 6 escalas de la enfermedad Sigatoka.

4 https://1drv.ms/f/c/02508de6d821047e/IgDf_T2yrVMxT6VVg6qaTrGLAeswTQWFSz6g1mstGwc9x1I?e=Ai29bI

Para cada imagen se delimitó un polígono que encierra la región analizada por el experto agrónomo para determinar el grado de la enfermedad. Para crear estos polígonos, se desarrolló una herramienta en JavaScript con la ayuda de la biblioteca D3.js, que permite cargar una imagen, delimitar una región poligonal en ella y exportar el polígono en un archivo json. La Figura siguiente muestra la interfaz de esta herramienta:



Figura 16. Herramienta desarrollada en JavaScript para delimitar la región de análisis de la enfermedad Sigatoka.

Arquitectura del sistema de visión artificial

El enfoque investigativo es de tipo cuantitativo, pues las imágenes son procesadas matemáticamente en matrices (redes neuronales) buscando identificar de manera automática, previo entrenamiento y etiquetación, cuál es la fase en la que se encuentra la enfermedad.

Para definir si la hipótesis se cumple se desarrollará experimentos con lo cual se podrá corroborar la efectividad de los métodos utilizados.

La arquitectura propuesta toma una imagen como entrada y entrega como salida un vector de probabilidades de 6 entradas, en el que cada entrada corresponde al grado de severidad de la enfermedad Sigatoka. Los tres bloques principales son el preprocesamiento, la extracción de características y la clasificación. La Figura 16 muestra su esquema general.

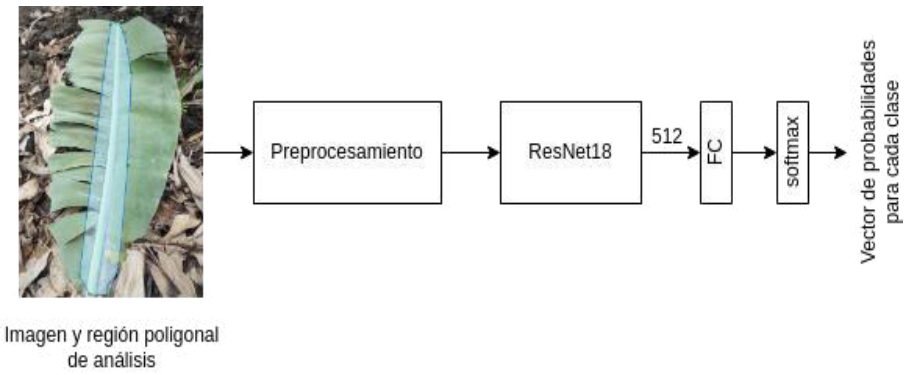


Figura 17. Esquema general del sistema de visión artificial para detección del grado de la enfermedad Sigatoka.

La arquitectura se compone de un preprocesamiento de la región poligonal de una imagen, seguido de la extracción de características utilizando la red neuronal ResNet18 y una capa de clasificación que

genera logits los cuales posteriormente pueden transformarse, mediante softmax en probabilidades asociadas a las clases.

Preprocesamiento de las imágenes

La etapa de preprocesamiento busca normalizar el ángulo y tamaño de la imagen de entrada, así como también el rango de valores de sus píxeles. Para normalizar el ángulo y tamaño de la imagen de entrada, primero se recorta el área de análisis. Luego, se encuentra el rectángulo que encierra esta región y, por último, se normaliza a cero grados con respecto al lado más grande del rectángulo. De esta manera, siempre se obtendrá una imagen en posición horizontal como entrada. Adicionalmente, se extrae solo la imagen correspondiente a la región y se redimensiona de tal manera que su ancho sea de 1000 píxeles, conservando su relación de aspecto. La siguiente figura ejemplifica este procedimiento:

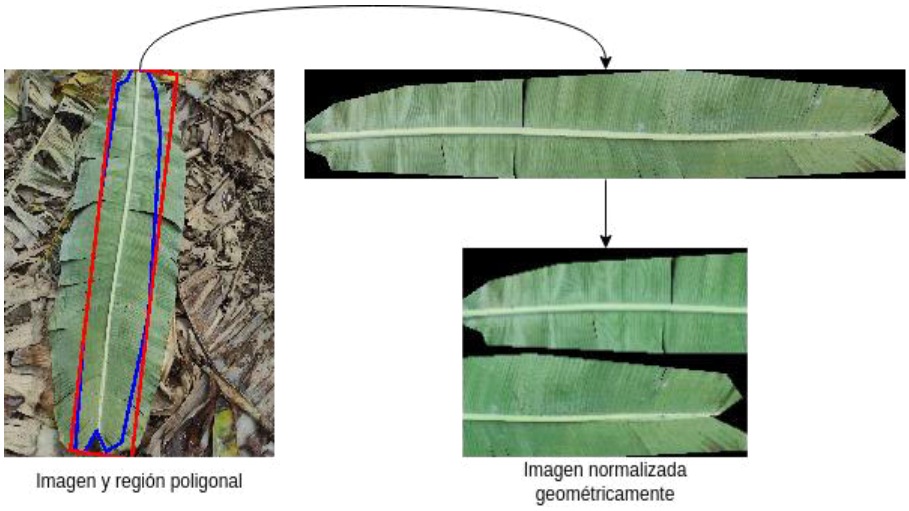


Figura 18. Flujo del procesamiento de una imagen.

En la primera etapa, se localiza el rectángulo que encierra la región poligonal de análisis, el cual se normaliza a un ángulo de 0 grados con respecto al lado más largo en la segunda etapa. En la última etapa, la imagen resultante se divide en dos mitades y se redimensiona a un tamaño de 224 × 224 píxeles para su procesamiento posterior.

Ahora bien, para que ResNet18 pueda procesar una imagen de entrada, el tamaño estándar (y para mantener compatibilidad con las imágenes de preentrenamiento) es de 224 × 224 píxeles. Sin embargo, redimensionar la imagen directamente a este tamaño no es una buena idea, ya que podríamos perder detalles importantes, especialmente a lo largo de la dirección horizontal. Para solucionar este problema, se ha optado por dividir la imagen normalizada a cero grados en dos mitades, y luego concatenar verticalmente las dos imágenes resultantes. De esta manera, la nueva imagen sigue conteniendo los mismos detalles que la imagen original, pero no pierde tantos detalles a lo largo de la dirección horizontal cuando se redimensiona a 224x224.

Es importante destacar que el anterior procedimiento funciona porque la red convolucional seguirá capturando los mismos detalles sin importar si la hoja se ve en dos mitades o completa. Esto se sustenta en una de las propiedades de las redes convolucionales, conocida como invarianza a la traslación, lo que significa que la red seguirá reconociendo las características en una imagen independientemente de su posición en el espacio.

Por último, cada canal de la imagen de entrada se normaliza con respecto a la media y desviación estándar de las imágenes de la base de

datos ImageNet. Este procedimiento tiene como objetivo eliminar estandarizar la distribución de los canales de entrada respecto de la utilizada en el preentrenamiento.

Extracción de características y entrenamiento del modelo

La extracción de características tiene como objetivo transformar una imagen de entrada en un vector que codifique los patrones de la imagen. Clásicamente, este procedimiento se realizaba con distintas estrategias conocidas como Hand Crafted, derivadas del conocimiento humano sobre un problema. Algunas de estas estrategias eran características Haar, LBP, filtros de Gabor, entre otros. Sin embargo, el resurgimiento de las redes convolucionales y bases de datos como ImageNet ha permitido entrenar redes convolucionales que luego pueden ser usadas como extractores de características en problemas de clasificación de imágenes. En particular, en este trabajo se usa la red convolucional ResNet18 entrenada en la base de datos ImageNet. Esta red neuronal consta de varias capas convolucionales y varias capas con lo cual la arquitectura termina con una capa completamente conectada de clasificación después del pooling global. Con el objetivo de usarla como extractor de características, se elimina la última capa de salida y se conserva el backbone convolucional preentrenado y se sustituye la capa fully connected final; el vector de características que alimenta esa capa tiene dimensión 512.

Tabla 5. Características para entrenar el modelo.

Componente	Configuración
Arquitectura	ResNet18 preentrenada

Framework	PyTorch
Transfer learning	Capas convolucionales congeladas
Tamaño de lote	4
Optimizador	SGD
Momentum	0,9
Learning rate	revisar
Scheduler	StepLR
Step size	7
Gamma	0,1
Pérdida	Cross-entropy
Data augmentation	Crop + flips

Detalles de implementación

La red neuronal se programó en Python usando la biblioteca PyTorch. Para todos los experimentos, se utilizó un tamaño de lote (batch) de entrenamiento igual a 4. Se utilizó el método de optimización de descenso de gradiente estocástico con una tasa de aprendizaje de 0.001 y una política de decaimiento en períodos de 7 con un factor gamma de 0.1. Además, se utilizó la técnica de aumento de datos mediante transformaciones aleatorias de volteo horizontal y vertical en PyTorch. A continuación, se describe algunos detalles importantes del código fuente.

Normalización geométrica de la región poligonal:

Este código (ver funcion normalize_region) se encarga de recortar la región poligonal de análisis y normalizarla a un ángulo con respecto a una referencia común. Para lograr esto, después de recortar la región, se encuentra el rectángulo mínimo que encierra dicha región y se rota de tal manera que su lado mayor

quede en cero grados.

Encuentra el rectángulo de contorno más pequeño para un conjunto de puntos.

Devuelve un conjunto de puntos que representan las esquinas del cuadro delimitador.

```
        :parametro points: una matriz nx2 de coordenadas

        :rval: una matriz nx2 de coordenadas

        """

        pi2 = np.pi/2.

        # obtener el contorno convexo de los puntos

        hull_points = points[ConvexHull(points).vertices]

        # calcular los ángulos de los bordes

        edges = np.zeros((len(hull_points)-1, 2))

        edges = hull_points[1:] - hull_points[:-1]

        angles = np.zeros((len(edges)))

        angles = np.arctan2(edges[:, 1], edges[:, 0])

        angles = np.abs(np.mod(angles, pi2))

        angles = np.unique(angles)
```

```
# encontrar matrices de rotación

# XXX ambas funcionan

rotations = np.vstack([

np.cos(angles),

5

np.cos(angles-pi2),

np.cos(angles+pi2),

np.cos(angles)]).T

# rotations = np.vstack([

# np.cos(angles),

# -np.sin(angles),

# np.sin(angles),

# np.cos(angles)]).T

rotations = rotations.reshape((-1, 2, 2))

# aplicar las rotaciones al contorno convexo

rot_points = np.dot(rotations, hull_points.T)

# encontrar los puntos de contorno
```

```
min_x = np.nanmin(rot_points[:, 0], axis=1)

max_x = np.nanmax(rot_points[:, 0], axis=1)

min_y = np.nanmin(rot_points[:, 1], axis=1)

max_y = np.nanmax(rot_points[:, 1], axis=1)

# encontrar el cuadro con el mejor área

areas = (max_x - min_x) * (max_y - min_y)

best_idx = np.argmin(areas)

# devolver el mejor cuadro

x1 = max_x[best_idx]

x2 = min_x[best_idx]

y1 = max_y[best_idx]

y2 = min_y[best_idx]

r = rotations[best_idx]

rval = np.zeros((4, 2))

rval[0] = np.dot([x1, y2], r)

rval[1] = np.dot([x2, y2], r)

rval[2] = np.dot([x2, y1], r)
```

```
        rval[3] = np.dot([x1, y1], r)

        return rval

        def remove_black_background(image):

        '''
```

Esta función remueve el fondo negro de los bordes de una imagen

```
        gray = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)

        _, thresh = cv2.threshold(gray, 0, 255,
cv2.THRESH_BINARY)

        contours, _ = cv2.findContours(thresh,
cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)

        max_area = 0

        max_cnt = None

        for cnt in contours:

        area = cv2.contourArea(cnt)

        if area > max_area:

        max_area = area

        max_cnt = cnt

        x, y, w, h = cv2.boundingRect(max_cnt)
```

return image[y:y+h, x:x+w].copy()

def normalize_region(img, raw_points, max_sz=1000):

Esta función recibe una imagen y una región poligonal como entradas, y devuelve la imagen recortada y normalizada a cero grados con respecto al lado mayor de la región poligonal. También se eliminan las partes fuera de la región poligonal, reemplazándolas por un fondo negro.

Aquí se obtiene el polígono que encierra la región poligonal.

pts = np.array(raw_points, np.int32) # Polígono.

bounding_rect = minimum_bounding_rectangle(pts) # Rectángulo envolvente.

rect = np.array(bounding_rect, np.int32).reshape((-1, 1, 2)) # Rectángulo envolvente.

6

Estos son los vértices del rectángulo que encierra la región poligonal.

p1 = bounding_rect[0]

p2 = bounding_rect[1]

p3 = bounding_rect[2]

p4 = bounding_rect[3]

```
p1[1] = -p1[1]

p2[1] = -p2[1]

p3[1] = -p3[1]

p4[1] = -p4[1]

# Aquí se busca el vector director con mayor tamaño, es decir la base del rectángulo.

vectors = [p2 - p1, p3 - p1, p4 - p1]

vectors = sorted(vectors, key=lambda v: np.linalg.norm(v))

if np.linalg.norm(vectors[0]) <= np.linalg.norm(vectors[1]):

v1 = vectors[0]

v2 = vectors[1]

else:

v1 = vectors[1]

v2 = vectors[0]

# v1 es el vector director de los lados de menor tamaño del rectángulo.

# v2 es el vector director de los lados de mayor tamaño del rectángulo.
```

```
        # Aquí encontramos el ángulo al que está rotado el rectángulo.
        angle = angle_with_horizontal(v2)
        # Recortando la imagen.
        img_cropped = crop_image(img, pts)
        # Aquí se redimensiona la imagen si su tamaño es superior a
max_sz.
        v2_norm = np.linalg.norm(v2)
        if v2_norm > max_sz:
        scale = max_sz / v2_norm
        h, w = img_cropped.shape[:2]
        new_w = int(w * scale)
        new_h = int(h * scale)
        # Redimensionando la imagen usando cv2.resize.
        img_cropped = cv2.resize(img_cropped, (new_w, new_h),
cv2.INTER_AREA)
        if v2[1] < 0:
        img_normalized = ndimage.rotate(img_cropped, 180 * angle /
np.pi, order=3)
```

else:

img_normalized = ndimage.rotate(img_cropped, -180 * angle / np.pi, order=3)

Eliminando el padding negro sobrante de la imagen final.

img_normalized = remove_black_background(img_normalized)

return img_normalized

Aumentación de datos:

En el siguiente código se describe la configuración en PyTorch para la realización de la aumentación de datos. Esta técnica se utiliza para aumentar artificialmente el conjunto de entrenamiento, a través de recortes aleatorios de la imagen y volteos horizontales y verticales.

data_transforms = {

'train': transforms.Compose([# Transformaciones para el conjunto de entrenamiento

transforms.Resize((int(224*1.2), int(224*1.2))), # Cambia el tamaño de la imagen a 1.2

,→ veces su tamaño original

transforms.RandomCrop(224), # Realiza un recorte aleatorio de tamaño 224x224 en la

,→ imagen

transforms.RandomHorizontalFlip(), # Invierte aleatoriamente la imagen horizontalmente

transforms.RandomVerticalFlip(), # Invierte aleatoriamente la imagen verticalmente

transforms.ToTensor(), # Convierte la imagen a un tensor de PyTorch

transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225]) # Normaliza la

,→ imagen con una media y desviación estándar predefinidas

]),

7

'val': transforms.Compose([# Transformaciones para el conjunto de validación

transforms.Resize((int(224*2), int(224*2))), # Cambia el tamaño de la imagen a 2 veces

,→ su tamaño original

transforms.RandomCrop(224), # Realiza un recorte aleatorio de tamaño 224x224 en la

,→ imagen

transforms.ToTensor(), # Convierte la imagen a un tensor de PyTorch

transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225]) # Normaliza la

,→ imagen con una media y desviación estándar predefinidas

]),

}

Configuraciones experimentales

Optimización:

El siguiente código presenta la configuración en PyTorch del entrenamiento de una red neuronal ResNet18. Primero se carga la red pre-entrenada y se congelan sus parámetros para utilizarla como extractor de características. Luego, se adapta la salida al nuevo número de clases y se configura la función de costo de entropía cruzada. Por último, se especifica la política de entrenamiento.

Cargar modelo ResNet-18 pre-entrenado

model_conv = torchvision.models.resnet18(pretrained=True)

Congelar los parámetros de todas las capas en el modelo

for param in model_conv.parameters():

param.requires_grad = False

```
# Obtener el número de características de la capa de salida del modelo ResNet-18
num_ftrs = model_conv.fc.in_features
# Reemplazar la capa de salida del modelo con una nueva capa lineal que tenga 6 salidas (6
,→ clases)
model_conv.fc = nn.Linear(num_ftrs, 6)
# Mover el modelo y los datos a la GPU si está disponible
model_conv = model_conv.to(device)
# Definir la función de pérdida que se usará durante el entrenamiento
criterion = nn.CrossEntropyLoss()
# Definir el optimizador que se usará para actualizar los pesos del modelo
optimizer_conv = optim.SGD(model_conv.fc.parameters(), lr=0.001, momentum=0.9)
# Definir el programador de tasa de aprendizaje que disminuirá la tasa de aprendizaje del
,→ optimizador después de 7 épocas
```

exp_lr_scheduler = lr_scheduler.StepLR(optimizer_conv, step_size=7, gamma=0.1)

Resultados e interpretación

Se evaluó el modelo con tres configuraciones distintas: Variación 1, Variación 2 y Variación 3. La Variación 1 corresponde al modelo entrenado con las 6 escalas de la enfermedad. La Variación 2 corresponde al modelo entrenado con 3 escalas de la enfermedad, obtenidas al combinar las imágenes de las escalas 0 y 1, 2 y 3, y 4 y 5 en una sola escala. La Variación 3 es el modelo entrenado con solo dos clases, obtenidas al combinar las imágenes de las escalas 0, 1 y 2 en una clase, y las imágenes de las escalas 3, 4 y 5 en la otra.

La Figura 19, Figura 20 y Figura 21 muestran las curvas de pérdida y exactitud obtenidas con los datos de prueba para cada una de las tres variaciones del modelo.

Para la variación 1, los resultados indican que, aunque la función de pérdida decrece para los datos de entrenamiento, la función de pérdida para los datos de validación solo disminuye levemente hasta alcanzar aproximadamente 1.5 en la época 8, y desde entonces se mantiene estable. De manera similar, aunque la exactitud para los datos de entrenamiento aumenta, la exactitud para los datos de prueba no mejora a medida que pasan las épocas. En consecuencia, podemos concluir que la variación 1 del modelo no generaliza adecuadamente los datos.

Esto se confirma cuando se examina la matriz de confusión (ver Figura 22a), en la que solo las clases 1 y 6 obtienen predicciones correctas, mientras que para el resto de las clases el modelo tiende a clasificarlas de manera errónea.

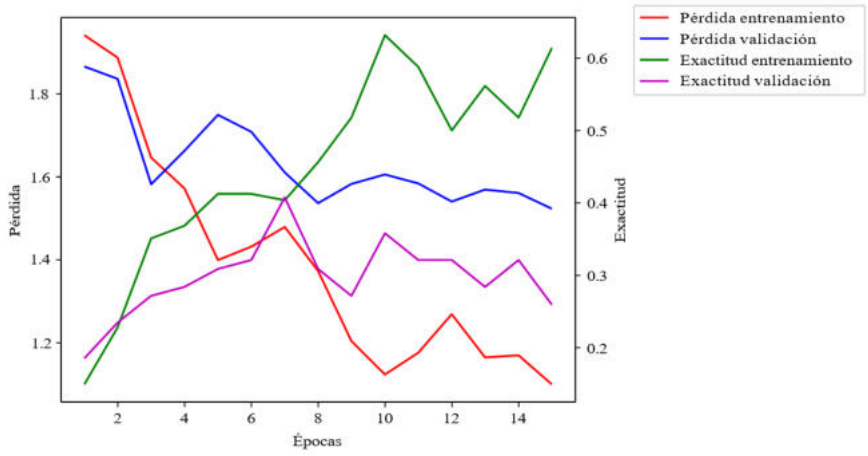


Figura 19. Curvas de perdida y exactitud para la variación 1 del modelo.

La variación 2 (ver Figura 20) del modelo presenta un mejor desempeño en comparación con la variación 1. Tanto la pérdida de entrenamiento como la pérdida de validación disminuyen a medida que pasan las épocas, alcanzando valores por debajo de 1, lo que es mucho menor que en la variación 1. Además, la gráfica de exactitud obtenida con los datos de validación muestra un comportamiento creciente, superando el 0.7 en las épocas 10 y 14. Este comportamiento nos permite confirmar que el modelo generaliza adecuadamente la mayoría de las clases. Podemos observar en la matriz de confusión de la variación 2 (ver Figura 22b) que la mayoría de las predicciones son correctas para la clase 0 y la clase 2. Sin embargo, también podemos observar que el modelo no puede generalizar la clase 1. Esto

posiblemente se deba a que es más fácil identificar los casos extremos de la enfermedad, es decir, la presencia o ausencia de la enfermedad, que identificar las escalas intermedias que pueden confundirse con hojas sanas o con hojas que presentan un grado leve de la enfermedad.

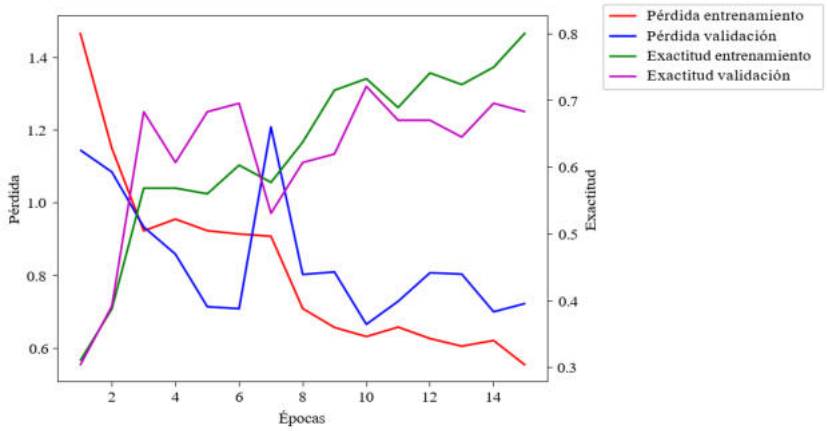


Figura 20. Curvas de perdida y exactitud para la variación 2 del modelo.Curvas de perdida y exactitud para la variación 2 del modelo.

El mejor desempeño se logra con la variación 3 del modelo (ver Figura 21). Las curvas de pérdida, tanto para los datos de entrenamiento como para los de prueba, disminuyen hasta alcanzar valores inferiores a 0.5. Asimismo, las gráficas de exactitud son crecientes, superando 0.9 en algunas épocas. Por lo tanto, se puede concluir que, en este caso, el modelo generaliza adecuadamente las dos clases, que representan la presencia o ausencia de enfermedad. Además, estos resultados son respaldados por los resultados de la matriz de confusión (ver Figura 22c), donde de 50 imágenes pertenecientes a la clase 0, 44 fueron clasificadas correctamente, y de 29 imágenes pertenecientes a la clase 1, 26 fueron clasificadas correctamente.

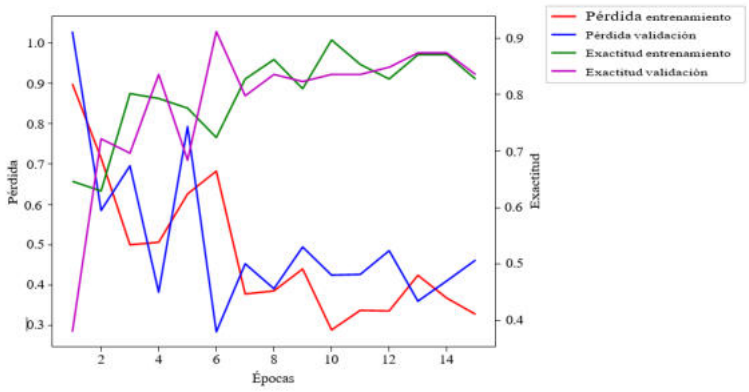


Figura 21. Curvas de perdida y exactitud para la variación 3 del modelo.

Adicionalmente, para la variación 1 del modelo se utilizó la salida softmax para construir la curva ROC que se muestra en la Figura 22. Es notable que la curva presenta un buen comportamiento muy por encima de la decisión aleatoria, y su AUC es de 0.96. La salida softmax de este modelo puede interpretarse como el grado de enfermedad de una hoja.

Procesamiento de Datos y Corroboración de Resultados

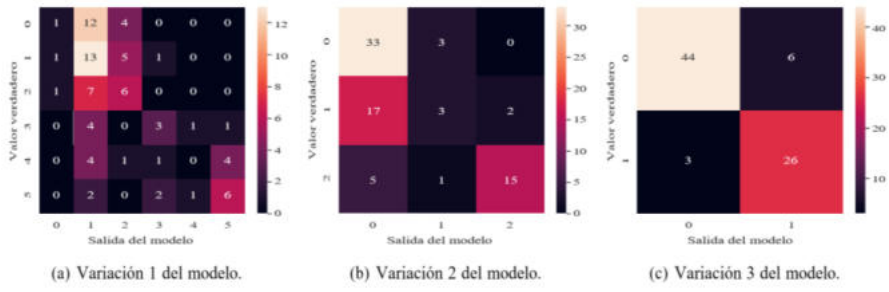


Figura 22. Matrices de confusión obtenidas en la validación de las variaciones 1, 2 y 3 del modelo.

Se observa una mejora en la clasificación a medida que se redujo la cantidad de clases, indicando una facilidad en la diferenciación de los extremos de la escala: planta sana y planta enferma.

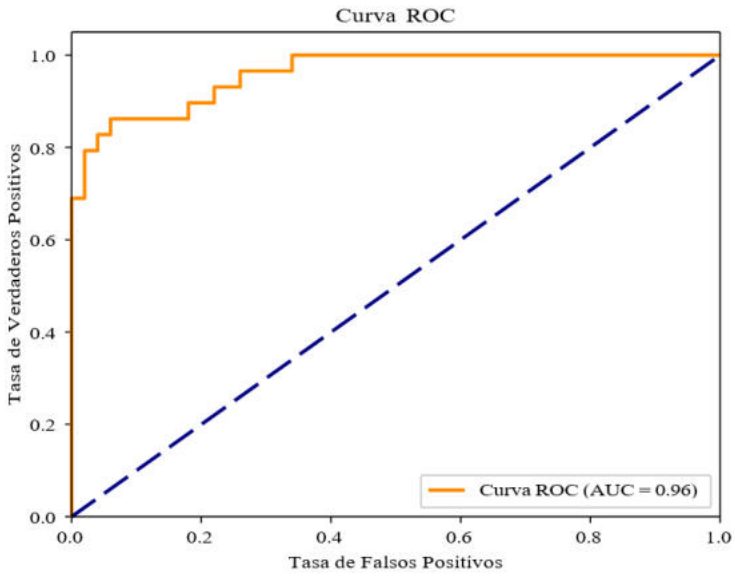


Figura 23. Curva ROC obtenida para la variación 3 del modelo.

Despliegue del modelo, limitaciones y lecciones aprendidas

La salida en este caso corresponde a la segunda componente del vector de la salida softmax, que puede interpretarse como el grado de enfermedad Sigatoka de la hoja.

Se creó un entorno productivo para los modelos desarrollados utilizando la biblioteca Flask. Esta herramienta permite cargar imágenes a través de una interfaz web, procesarlas y devolver los resultados. En el lado del cliente, la interfaz permite cargar una imagen, seleccionar el polígono de la región de análisis y enviarla para su

procesamiento. En el lado del servidor, la aplicación Flask recibe el mensaje mediante un mensaje POST y lo envía a una cola para que el proceso creado con la biblioteca PyTorch procese la imagen y devuelva los resultados. Por último, los resultados se envían al cliente y se muestran en letras rojas debajo de la imagen. A continuación, se muestra un esquema general de la arquitectura productiva implementada:

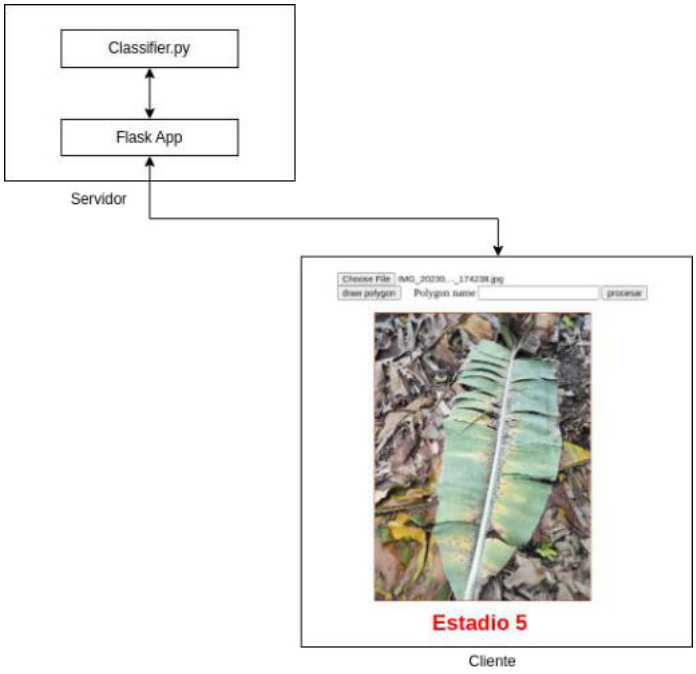


Figura 24. Arquitectura cliente servidor implementada para desplegar en productivo los modelos entrenados.

El tamaño de la data[5] y la distribución del conjunto de datos fueron suficientes para obtener resultados promisorios en la clasificación agregada, sin embargo, resultaron insuficientes para discriminar

5 https://1drv.ms/f/c/02508de6d821047e/IgDf_T2yrVMxT6VVg6qaTrGLAeswTQWFSz6g1mstGwc9x1I?e=Ai29bI

consistentemente los seis estadios de severidad. Se recomienda entrenar el modelo con más imágenes para su aplicación eficiente en la industria, pero para efectos académicos de demostrar el uso de la IA como ejemplo, los autores consideraron suficiente.

1.8.9 Aplicación precisa de tratamientos

La inteligencia artificial también optimiza la forma en que se aplican pesticidas. Robots agrícolas con sistemas de visión artificial, como los desarrollados por **Blue River Technology**, pueden identificar individualmente malezas o insectos dañinos y aplicar microdosis del químico necesario únicamente donde se requiere. Esta técnica, conocida como **"pulverización selectiva"**, reduce el uso de agroquímicos en más del 80%, minimiza el daño ambiental y evita la generación de resistencia en las plagas (Blue River Technology, 2022).

Además, en entornos protegidos como invernaderos, se han desarrollado sistemas automáticos de liberación de insectos benéficos, como avispas parasíticas o mariquitas, activados por algoritmos que detectan la presencia de plagas específicas, promoviendo un control biológico guiado por IA (Sánchez-Molina et al., 2021).

1.8.10 Impacto en la sostenibilidad y productividad

La integración de IA en el control de plagas contribuye no solo a aumentar la productividad de los cultivos, sino también a una agricultura más sostenible. Al reducir la dependencia de pesticidas y mejorar la eficiencia de los tratamientos, se protege la biodiversidad, se mejora la salud del suelo y se previene la contaminación del agua (FAO,

2022). Además, los agricultores pueden planificar con mayor anticipación y precisión, reduciendo pérdidas económicas y riesgos fitosanitarios.

No obstante, la implementación de estos sistemas aún enfrenta obstáculos como el acceso limitado a tecnologías avanzadas en zonas rurales, la necesidad de conectividad constante y la capacitación técnica de los usuarios. Asimismo, se requiere una mayor inversión en modelos de IA entrenados con datos locales, dado que muchas plagas varían por región y condiciones agroecológicas (Ramesh et al., 2022).

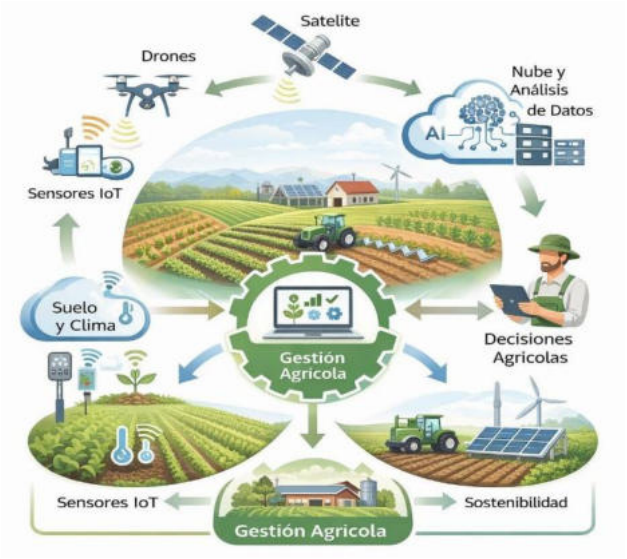


Figura 25. Ecosistema tecnológico de la Agricultura Inteligente 4.0.

Nota. Elaboración propia con base en Wolfert et al. (2017), Liakos et al. (2018) y Kamilaris et al. (2017).

La Figura 25 muestra el ecosistema tecnológico de la Agricultura Inteligente 4.0, el cual integra múltiples fuentes de datos y tecnologías

digitales para optimizar los procesos productivos agrícolas. En este sistema, sensores IoT instalados en el campo, drones y satélites recopilan información sobre el estado de los cultivos, el suelo y las condiciones climáticas. Estos datos son transmitidos a plataformas de almacenamiento y procesamiento en la nube, donde algoritmos de inteligencia artificial y análisis de Big Data permiten generar modelos predictivos y recomendaciones para la toma de decisiones. Este enfoque basado en datos permite mejorar la eficiencia en el uso de los recursos, incrementar la productividad agrícola y reducir el impacto ambiental de la producción, consolidando un nuevo paradigma de agricultura digital orientado a la sostenibilidad.

1.9 Casos de éxito en el uso de Big Data en agricultura

El Big Data ha revolucionado múltiples sectores productivos, y la agricultura no es la excepción. A través de la recopilación, almacenamiento y análisis de grandes volúmenes de datos provenientes de sensores, drones, imágenes satelitales, maquinaria agrícola e informes meteorológicos, se han logrado transformar prácticas agrícolas tradicionales en sistemas de producción de alta precisión, sostenibles y rentables. Los casos de éxito en diversos países demuestran que el uso estratégico del Big Data puede generar impactos positivos significativos en la toma de decisiones, la optimización de recursos y el aumento de rendimientos.

1.9.1 John Deere y la agricultura de precisión en Estados Unidos

John Deere, una de las compañías más emblemáticas del sector agrícola, ha sido pionera en la integración de Big Data en sus sistemas de

maquinaria inteligente. Sus tractores y cosechadoras están equipados con sensores que recogen datos sobre humedad del suelo, calidad de grano, uso de combustible y desempeño de los operarios. Esta información es enviada en tiempo real a la plataforma *John Deere Operations Center*, donde los agricultores pueden visualizar mapas de rendimiento, compararlos con datos históricos y tomar decisiones fundamentadas sobre siembra, riego o aplicación de insumos (John Deere, 2021).

Además, gracias a algoritmos predictivos alimentados con datos históricos de más de 100 millones de hectáreas, los agricultores pueden anticipar condiciones adversas y optimizar sus calendarios agrícolas, lo que ha mejorado en promedio un 15% la eficiencia operativa (Zhang & Kovacs, 2012).



Figura 26. Tractor con tecnología de vanguardia.

Nota. Tomada del sitio web https://www.maquinariacarran.cl/tractor-john-deere-5075e2

1.9.2 Agrosmart en América Latina

En Brasil, la empresa Agrosmart ha desarrollado una plataforma basada en Big Data e inteligencia artificial que recolecta información desde sensores de campo, imágenes satelitales y datos meteorológicos, con el objetivo de asesorar a los agricultores en tiempo real sobre riego, fertilización y control de plagas. Gracias a su uso, empresas productoras de caña de azúcar y soja han logrado reducir hasta un 60% el consumo de agua y un 30% en fertilizantes, mientras incrementaban los rendimientos (Agrosmart, 2020).

La adaptabilidad de Agrosmart a los cultivos de clima tropical ha permitido su expansión en países como Colombia, Perú y México, demostrando cómo el Big Data puede responder a condiciones agroecológicas diversas.

1.9.3 Climate FieldView y la predicción del rendimiento

La plataforma **Climate FieldView**, desarrollada por *The Climate Corporation*, propiedad de Bayer, ha sido un referente en el uso del Big Data aplicado a la predicción de rendimientos y análisis espacial de cultivos. Su modelo analiza datos georreferenciados de parcelas agrícolas, combinados con condiciones meteorológicas, historial de suelos y manejo agronómico. Esto permite a los agricultores tomar decisiones de precisión para cada zona del lote.

En Estados Unidos, agricultores que utilizan FieldView han reportado incrementos de rendimiento de entre un 5% y 10% en cultivos como

maíz y soja, junto con una reducción de pérdidas por estrés hídrico o manejo inadecuado de insumos (Bayer, 2021).

1.9.4 Proyecto 365FarmNet en Europa

En Alemania, la plataforma 365FarmNet integra datos de diferentes fuentes: maquinaria agrícola, sensores del suelo, condiciones climáticas y bases de datos agronómicas. El sistema analiza automáticamente estos datos para emitir recomendaciones personalizadas, desde la siembra hasta la cosecha. Con esta solución, los agricultores pueden planificar sus labores agrícolas con base en el rendimiento esperado, gestionar los costos operativos y reducir impactos ambientales.

Según reportes del proyecto, los agricultores que adoptaron 365FarmNet experimentaron mejoras en la eficiencia de uso de fertilizantes (hasta un 20%) y una disminución en la huella de carbono de sus actividades agrícolas (365FarmNet, 2021).

Tabla 6. Comparación de plataformas de Big Data aplicadas a la agricultura.

Plataforma	Región	Tipo de tecnología	Aplicación principal	Impacto reportado
John Deere Operations Center	Estados Unidos	Sensores en maquinaria agrícola + análisis de datos	Monitoreo de rendimiento y gestión de cultivos	Mejora de la eficiencia operativa en 15%
Agrosmart	Brasil / América	Sensores IoT + IA + análisis climático	Gestión inteligente del	Reducción del consumo de

	Latina		rieg o y fertilización	agua hasta 60%
Climate FieldView	Estados Unidos	Big Data geoespacial + análisis predictivo	Predicción de rendimiento y análisis del suelo	Incremento de l rendimient o entre 5% y 10%
365FarmNe t	Alemania / Europa	Plataforma digital de gestión agrícola	Planificación agrícola y	Reducción del uso de fertilizantes hasta optimizació n de insumos 20 %

Nota. Elaboración propia a partir de John Deere (2021), Agrosmart (2020), Bayer (2021) y 365FarmNet (2021).

Como se observa en la Tabla 6, las plataformas de Big Data aplicadas a la agricultura presentan diferencias en su enfoque tecnológico y en los recursos agrícolas que optimizan. El análisis comparativo de estos casos evidencia que el éxito del uso de Big Data en la agricultura depende de tres factores fundamentales: la disponibilidad de datos de alta calidad, la integración de plataformas digitales capaces de procesar grandes volúmenes de información y la adopción tecnológica por parte de los agricultores. Mientras que, en países con alta digitalización agrícola,

como Estados Unidos y Alemania, las plataformas de análisis de datos se integran directamente con maquinaria inteligente y sistemas de gestión agrícola, en regiones de América Latina las soluciones tecnológicas tienden a enfocarse en la optimización de recursos específicos como el riego o la fertilización. Esta diversidad de enfoques refleja las distintas realidades agroproductivas, pero también demuestra que el Big Data tiene un potencial transversal para mejorar la productividad, la sostenibilidad y la resiliencia de los sistemas agrícolas frente al cambio climático y la variabilidad climática.

1.10 Gobernanza de datos agrícolas y plataformas digitales

A medida que el uso de Big Data se expande dentro del sector agrícola, surge la necesidad de establecer marcos de gobernanza de datos que garanticen un uso transparente, seguro y equitativo de la información generada en los sistemas productivos. La agricultura digital depende cada vez más de la recopilación continua de datos provenientes de sensores, drones, estaciones meteorológicas, maquinaria agrícola conectada y plataformas de gestión digital. Este volumen creciente de información plantea interrogantes importantes sobre la propiedad de los datos, la privacidad de la información y el acceso equitativo a los sistemas tecnológicos.

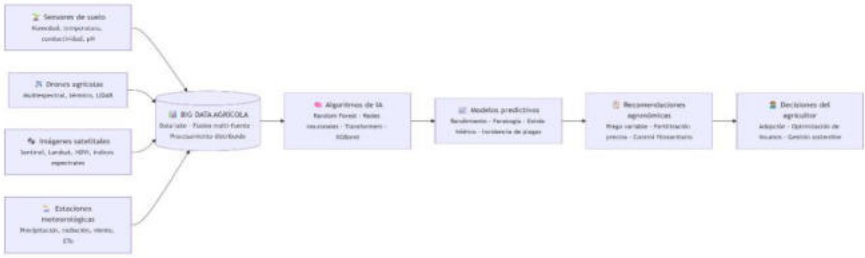


Figura 27. Flujo de datos en sistemas de agricultura digital.

Nota. Adaptado de Kamilaris et al. (2017) y Wolfert et al. (2017).

El flujo de datos comienza con la captura desde sensores de suelo, drones agrícolas, imágenes satelitales y estaciones meteorológicas. Estas fuentes convergen en una plataforma de Big Data Agrícola que integra y estandariza la información. Posteriormente, algoritmos de inteligencia artificial procesan los datos para alimentar modelos predictivos de rendimiento, fenología y riesgos fitosanitarios. A partir de estos modelos se generan recomendaciones agronómicas precisas (riego variable, fertilización localizada, control de plagas), que finalmente apoyan las decisiones del agricultor hacia una gestión sostenible y eficiente.

En muchos casos, los datos agrícolas generados en las explotaciones productivas son recopilados por plataformas tecnológicas desarrolladas por grandes empresas del sector AgTech. Estas plataformas procesan la información y generan recomendaciones para los agricultores, pero también pueden utilizar los datos recopilados para fines comerciales o de investigación. Este escenario ha generado debates sobre quién debe ser considerado el propietario legítimo de los datos agrícolas: el agricultor que genera la información, la empresa que desarrolla la

plataforma tecnológica o ambos actores de manera compartida (Bronson & Knezevic, 2016).

Diversas organizaciones internacionales han comenzado a promover principios de gobernanza de datos agrícolas orientados a garantizar la transparencia y la protección de los productores. La Organización de las Naciones Unidas para la Alimentación y la Agricultura ha propuesto marcos regulatorios que promueven el acceso abierto a los datos agrícolas, la interoperabilidad entre plataformas tecnológicas y el respeto a la privacidad de los agricultores (FAO, 2021).

Asimismo, el desarrollo de estándares internacionales para la gestión de datos agrícolas resulta fundamental para garantizar la interoperabilidad entre diferentes sistemas tecnológicos. La falta de estándares comunes puede dificultar la integración de datos provenientes de diferentes dispositivos o plataformas, lo que limita el potencial de los sistemas de inteligencia artificial aplicados a la agricultura.

Desde una perspectiva estratégica, la gobernanza de datos agrícolas también tiene implicaciones para el desarrollo de políticas públicas. Los gobiernos pueden utilizar información agregada proveniente de sistemas agrícolas digitales para diseñar políticas más efectivas relacionadas con la seguridad alimentaria, la gestión de recursos hídricos y la adaptación al cambio climático.

En este contexto, la gobernanza de datos se convierte en un elemento clave para el desarrollo sostenible de la agricultura digital, ya que permite garantizar que los beneficios de las tecnologías basadas en

datos se distribuyan de manera equitativa entre los distintos actores del sistema agroalimentario.

1.11 Perspectivas futuras de la agricultura inteligente

El futuro de la agricultura se perfila cada vez más como un sistema altamente digitalizado, interconectado y automatizado. La convergencia entre inteligencia artificial, Big Data, Internet de las Cosas, robótica agrícola y tecnologías de teledetección está configurando un nuevo paradigma productivo conocido como agricultura inteligente o agricultura digital.

Uno de los avances más prometedores en este ámbito es el desarrollo de sistemas agrícolas completamente autónomos. Los robots agrícolas equipados con sensores avanzados y algoritmos de inteligencia artificial podrán realizar tareas como la siembra, el monitoreo de cultivos, el control de malezas y la cosecha con un nivel de precisión superior al de los métodos tradicionales (Duckett et al., 2018).

Asimismo, el desarrollo de plataformas de análisis de datos cada vez más sofisticadas permitirá integrar información proveniente de múltiples fuentes, incluyendo sensores de campo, imágenes satelitales, registros climáticos y datos genéticos de cultivos. Esta integración facilitará el desarrollo de modelos predictivos más avanzados que podrán anticipar riesgos agrícolas y optimizar la gestión de los sistemas productivos.

Otro aspecto relevante del futuro de la agricultura inteligente es la incorporación de tecnologías emergentes como los gemelos digitales, la

computación cuántica aplicada al análisis de datos agrícolas y el uso de blockchain para garantizar la trazabilidad de los alimentos.

En conjunto, estas innovaciones tecnológicas tienen el potencial de transformar profundamente la forma en que se producen, distribuyen y consumen los alimentos a nivel global. La agricultura del futuro será cada vez más basada en datos, más precisa en el uso de recursos y más orientada hacia la sostenibilidad ambiental.



Figura 28. Modelo conceptual de agricultura inteligente basada en inteligencia artificial y Big Data.

Nota. Elaboración propia con base en Wolfert et al. (2017), Liakos et al. (2018) y Kumar et al. (2023).

Estos casos demuestran que el uso de Big Data no solo mejora los resultados económicos de las explotaciones agrícolas, sino que también permite prácticas más sostenibles y resilientes frente al cambio climático. La combinación de tecnologías como sensores IoT, aprendizaje automático y plataformas de análisis de datos está transformando la forma de cultivar, promoviendo una agricultura basada en evidencia, adaptable y orientada a la eficiencia.

Desde una perspectiva tecnológica, la integración de inteligencia artificial y Big Data en los sistemas agrícolas representa un cambio estructural en la forma en que se toman decisiones en el sector agropecuario. La posibilidad de analizar grandes volúmenes de datos

provenientes de sensores, estaciones meteorológicas, drones e imágenes satelitales permite desarrollar sistemas de apoyo a la toma de decisiones basados en evidencia. Esto no solo mejora la precisión de las estimaciones de rendimiento y la gestión de insumos, sino que también facilita la adaptación de los sistemas agrícolas frente a fenómenos climáticos extremos y variabilidad ambiental.

No obstante, el potencial de estas tecnologías aún enfrenta desafíos importantes relacionados con la disponibilidad de infraestructura digital, el acceso a tecnologías avanzadas por parte de pequeños agricultores y la necesidad de desarrollar modelos adaptados a condiciones agroecológicas locales. En este sentido, el futuro de la agricultura inteligente dependerá no solo del desarrollo tecnológico, sino también de la implementación de políticas públicas que promuevan la digitalización del sector agrícola, la formación técnica de los productores y la generación de ecosistemas de innovación que faciliten la transferencia tecnológica. De esta manera, la inteligencia artificial y el Big Data pueden consolidarse como herramientas estratégicas para construir sistemas agrícolas más productivos, resilientes y sostenibles.

CAPÍTULO II

2 AGRICULTURA SOSTENIBLE Y TECNOLOGÍAS VERDES

La FAO (2022) proyecta que la demanda mundial de alimentos podría crecer más de un 60 % hacia el año 2050, una cifra que resume por sí sola la magnitud del reto que enfrenta el sistema agroalimentario. Ese crecimiento se produce, además, en un escenario adverso: la población mundial sigue en aumento, los recursos naturales están cada vez más presionados, los ecosistemas se degradan a un ritmo acelerado y el cambio climático intensifica sus efectos año tras año. La convergencia de estos factores obliga a repensar, desde sus bases, el modelo de producción agrícola vigente.

El modelo agrícola tradicional, dependiente del uso intensivo de agua, fertilizantes químicos y combustibles fósiles, difícilmente puede sostenerse bajo ese escenario. Por eso ha ganado terreno la llamada agricultura sostenible: un enfoque que no renuncia a la productividad, pero que la condiciona a la conservación de los recursos naturales y al bienestar de las comunidades que dependen de ellos.

Dentro de ese paradigma, las tecnologías verdes cumplen un papel central: optimizan el uso de los recursos, reducen el impacto ambiental y aumentan la capacidad de los sistemas agrícolas para resistir condiciones adversas. El abanico es amplio, va desde el riego inteligente apoyado en inteligencia artificial hasta las energías renovables, la agricultura vertical y los sistemas de producción en

entornos controlados, y es precisamente esa diversidad la que se explora en las siguientes secciones.

Tabla 7. Tecnologías verdes aplicadas a la agricultura sostenible.

Tecnología	Principio tecnológico	Aplicación agrícola	Beneficio ambiental
Riego inteligente	Sensores IoT + IA	Control automático del riego según humedad del suelo	Reducción del consumo de agua
Energía solar agrícola	Paneles fotovoltaicos	Energía para sistemas de riego y maquinaria	Reducción de emisiones de carbono
Biogás agrícola	Digestión de anaerobia residuos	Generación de energía y biofertilizantes	Economía circular y reducción de residuos
Agricultura vertical	Sistemas y hidropónicos LED	Producción en espacios urbanos controlados	Uso eficiente del suelo y agua
Agricultura de precisión	Big Data + sensores	Aplicación localizada de insumos	Reducción de agroquímicos

La Tabla 7 sintetiza esta diversidad tecnológica: herramientas digitales, energías renovables y sistemas de producción innovadores que, combinados, reducen el impacto ambiental de la actividad agrícola, optimizan la productividad de los cultivos y fortalecen la resiliencia de los sistemas frente al cambio climático.

En esa misma línea, Facuy Delgado y Arcos-Jacome (2026) sostienen que los modelos de inteligencia ambiental contribuyen de forma

significativa a una gestión más sostenible de los recursos y a sistemas productivos más resistentes frente a desafíos ambientales complejos.

A esto se suma la Agricultura 4.0: un modelo productivo que integra sensores, plataformas de análisis de datos y automatización, y que basa sus decisiones en el análisis de información en tiempo real (Wolfert et al., 2017).

Con ese punto de partida, este capítulo analiza en profundidad las principales tecnologías sostenibles aplicadas a la agricultura: cómo funcionan, qué beneficios y limitaciones presentan, y de qué manera inciden en lo ambiental y en lo social. El propósito es ofrecer una visión integral de cómo la innovación tecnológica puede contribuir a sistemas agrícolas más eficientes, sostenibles y resilientes.

2.1 Tecnologías para la gestión eficiente del agua (riego inteligente)



Figura 29. Arquitectura de sistema de un modelo IoT de riego.

El paso hacia esquemas de riego inteligente no responde únicamente a una necesidad tecnológica; expresa una transformación estructural en la forma de gestionar el agua dentro de los sistemas agroproductivos. Por eso conviene entenderlo como un componente central de la agricultura de precisión, donde las decisiones se apoyan en datos en tiempo real, modelos predictivos y algoritmos de optimización (Wolfert et al., 2017).

Estos sistemas se organizan, en términos generales, en tres capas. La de adquisición de datos está formada por sensores distribuidos en el campo que registran variables edáficas, climáticas y fisiológicas del cultivo. La de procesamiento corresponde a plataformas analíticas, normalmente en la nube, donde se aplican modelos matemáticos y algoritmos de inteligencia artificial. Y la de ejecución activa el riego de forma automatizada, ajustando caudales y frecuencias según lo que recomiendan esos modelos (Zhang et al., 2019).

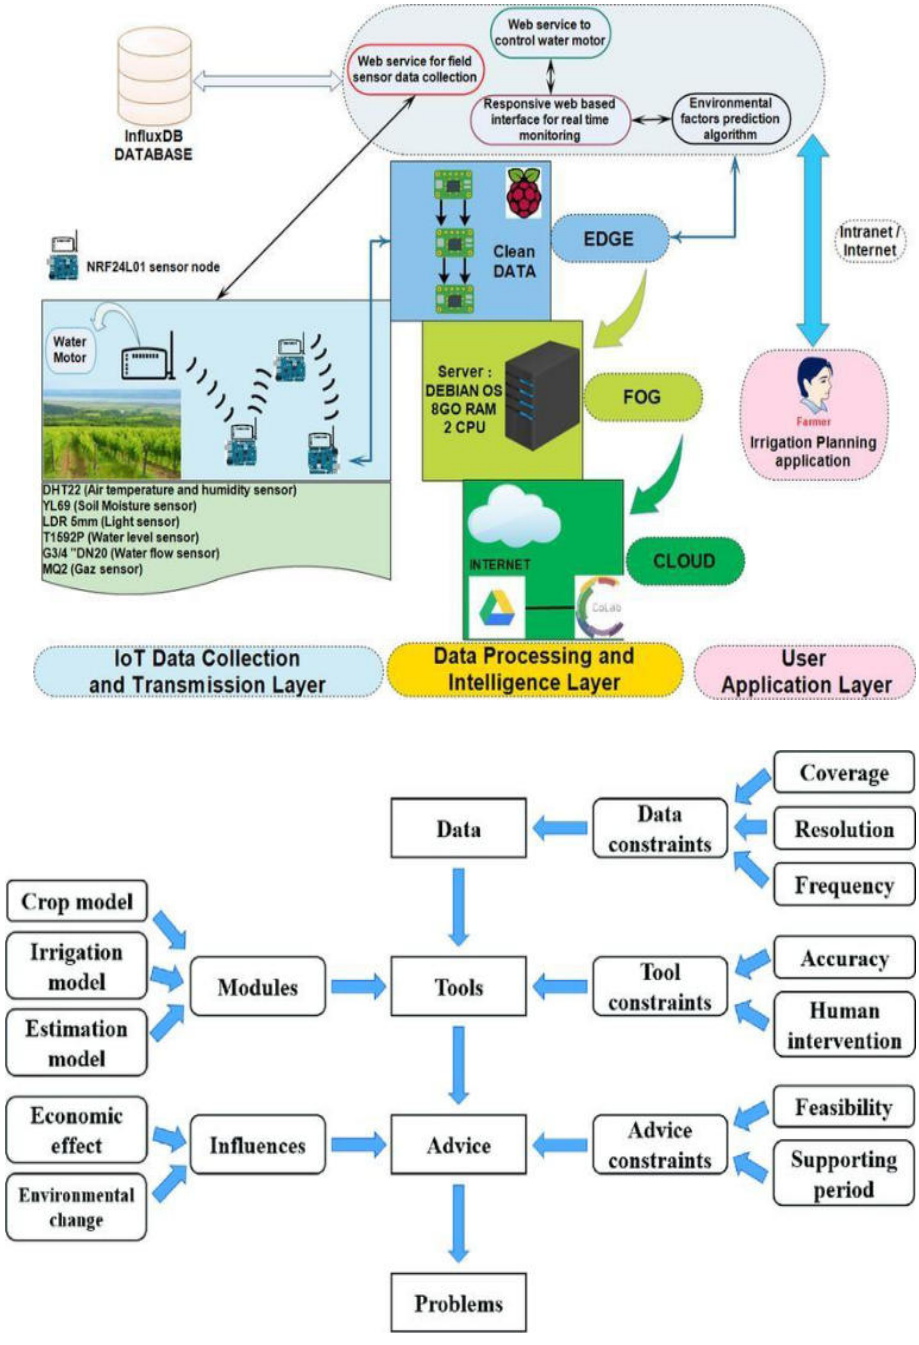


Figura 30. Arquitectura propuesta de sistema de agricultura inteligente basado en IoT.

Nota. De “An IoT Low-Cost Smart Farming for Enhancing Irrigation Efficiency of Smallholders Farmers”, por A. Dahane, R. Benameur, y B. Kechar, 2022, Wireless Personal Communications. https://doi.org/10.1007/s11277-022-09915-4

Uno de los aspectos más determinantes en el diseño de estos sistemas es la modelización de la evapotranspiración del cultivo (ETc), indicador clave para estimar las necesidades hídricas. El modelo físico de Penman-Monteith ha sido, tradicionalmente, la referencia obligada; sin embargo, Kumar et al. (2023) muestran que incorporar técnicas de machine learning mejora la precisión de estas estimaciones, al capturar relaciones no lineales entre variables climáticas y fisiológicas que el modelo clásico no logra representar del todo.

Algoritmos como Random Forest, Support Vector Machines y redes neuronales profundas se han utilizado ampliamente para modelar esta dinámica hídrica. Su valor no está solo en estimar la demanda de agua, sino en anticipar escenarios de estrés hídrico bajo distintas condiciones climáticas, una capacidad especialmente relevante en regiones vulnerables al cambio climático (Liakos et al., 2018).

La teledetección aporta otra pieza del análisis. Las imágenes satelitales y los drones con sensores multiespectrales permiten evaluar el estado hídrico del cultivo a escala espacial y detectar variaciones dentro de una misma parcela que los métodos tradicionales no logran captar. Índices como el NDVI y el NDWI se emplean para identificar estrés hídrico y ajustar el riego de manera diferenciada según la zona (Maimaitijiang et al., 2020).

El resultado, en términos agronómicos, es una mejora directa en la eficiencia del uso del agua (WUE). Basso y Antle (2020) documentan incrementos de más del 40 % en esa eficiencia, gracias a la reducción de pérdidas por evaporación y lixiviación y a una mejor disponibilidad de agua en los momentos críticos del desarrollo del cultivo.

Nada de esto está exento de dificultades. La heterogeneidad de las condiciones agroecológicas complica la generalización de los modelos predictivos, y la calidad de los datos es un factor crítico: un error de medición o una inconsistencia en las series temporales puede afectar de forma directa la precisión de los algoritmos.

A eso se suma la inversión inicial que exige su implementación, que suele quedar fuera del alcance del pequeño productor. Superar esa barrera requiere modelos de negocio inclusivos y políticas públicas que faciliten el acceso a la tecnología, de modo que la transición hacia sistemas más sostenibles no deje atrás a quienes menos recursos tienen (FAO, 2023).

El beneficio, en clave de sostenibilidad, va más allá del ahorro de agua: al reducir la lixiviación de nutrientes, una aplicación más precisa del riego también disminuye el uso de fertilizantes y la contaminación del suelo y del agua, mejorando la eficiencia general del sistema productivo.

Por todo esto, el riego inteligente se perfila como una de las tecnologías clave para enfrentar el futuro agrícola: permite gestionar el recurso hídrico con más eficiencia, precisión y sostenibilidad.

2.2 Energías renovables en la agricultura (paneles solares, biogás)

Reducir la huella de carbono del sector agropecuario pasa, en buena medida, por transitar hacia sistemas energéticos sostenibles. Durante décadas, la maquinaria, el riego y los procesos de transformación agrícola han dependido de combustibles fósiles, una dependencia que explica gran parte de las emisiones de gases de efecto invernadero (GEI) del sector (FAO, 2022).

2.2.1 Energía solar

La energía solar y el biogás han ganado terreno como respuesta a ese problema. Más allá de reducir emisiones, ambas fuentes abren oportunidades concretas para mejorar la eficiencia económica de los sistemas productivos.



Figura 31. Paneles solares para el riego.

Nota. De "Solar-Powered Irrigation: Unleashing the Sun's Potential for Your Farm", por GES Energy, 2024 (https://www.gesenergy.com.au/solar-powered-irrigation-unleashing-the-sun-spotential-for-your-farm).



Figura 32. Paneles solares, vista aérea de la parcela.

Nota. De “Solar-Powered Irrigation: Unleashing the Sun’s Potential for Your Farm”, por GES Energy, 2024 (https://www.gesenergy.com.au/solar-powered-irrigation-unleashing-the-sun-spotential-for-your-farm).

La caída sostenida en el costo de los paneles solares durante las últimas décadas explica buena parte de su adopción en el riego agrícola, al permitir que los productores reduzcan su dependencia de fuentes de energía convencionales. Un paso más allá lo representan los sistemas agrivoltaicos, que combinan producción agrícola y generación de energía en un mismo espacio: además de generar electricidad, reducen la evaporación del suelo y protegen los cultivos frente a condiciones climáticas extremas.

2.2.2 Biogas

El biogás, por su parte, ofrece una salida eficiente a un problema distinto: qué hacer con los residuos orgánicos. La digestión anaerobia convierte residuos agrícolas y pecuarios en energía y, de paso, genera biofertilizantes como subproducto. Es, en ese sentido, un mecanismo de economía circular que cierra ciclos de nutrientes y reduce la dependencia de insumos externos (Kshetri, 2021).

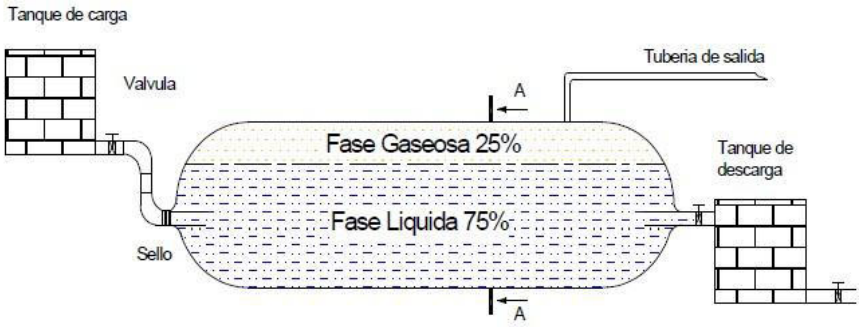


Figura 33. Diseño de biodigestor.

Nota. De "Diseño de un biodigestor de excremento para generación de biogás vía simulación con el software SIMBA®", por A. C. Lozano Ruíz, C. A. Sánchez Montealegre, y J. G. Ardila Marín, 2020, *I+ región*. https://doi.org/10.25054/22161325.2779

El uso de energías renovables en la agricultura reduce de forma significativa las emisiones de GEI y contribuye así a la mitigación del cambio climático. Tiene, además, un efecto que suele pasar desapercibido: la generación descentralizada de energía fortalece la

resiliencia de los sistemas agrícolas, sobre todo en zonas rurales donde el acceso a la red eléctrica sigue siendo limitado.

Su adopción a gran escala, sin embargo, choca con obstáculos conocidos: la inversión inicial, la infraestructura disponible y la necesidad de conocimientos técnicos especializados. Políticas de incentivo y programas de capacitación son, en ese sentido, condición casi indispensable para superarlos.

2.3 Agricultura vertical y cultivos en entornos controlados



Figura 34. Cultivo controlado.

Nota. Adaptado de sistemas de agricultura en ambiente controlado (CEA) utilizados en producción intensiva. Fuente: Benke y Tomkins (2017).

Pocas transformaciones en la producción de alimentos del siglo XXI resultan tan disruptivas como la agricultura vertical y los sistemas de cultivo en entornos controlados (Controlled Environment Agriculture, CEA). Benke y Tomkins (2017) la explican como una respuesta directa a la creciente urbanización, la escasez de tierras agrícolas y la necesidad de producir alimentos de forma eficiente en un clima cada vez más impredecible.

Su lógica es distinta a la de la agricultura tradicional: en lugar de extenderse sobre el terreno, se apila en estructuras cerradas donde tecnologías avanzadas controlan con precisión cada variable ambiental. El resultado es un uso más eficiente del espacio, un menor consumo de agua y una independencia casi total de las condiciones climáticas externas, tres razones por las que se ha convertido en una alternativa viable para producir alimentos en entornos urbanos y periurbanos.



Figura 35. Sistema de agricultura vertical en entorno controlado con iluminación LED y cultivo hidropónico.

Nota. Adaptado de sistemas de agricultura en ambiente controlado (CEA) utilizados en producción intensiva. Fuente: Benke y Tomkins (2017).

La Figura 35 ilustra bien este principio: al distribuir el cultivo en múltiples niveles, el mismo espacio físico rinde varias veces más superficie productiva.

2.3.1 Fundamentos tecnológicos

El control preciso de las condiciones de cultivo se apoya en varias tecnologías, entre las que destacan la hidroponía, la aeroponía y la acuaponía. Las tres comparten un mismo principio: sustituir el suelo por soluciones nutritivas que entregan los nutrientes de forma más eficiente.

La hidroponía es, de las tres, la más estudiada en términos de eficiencia hídrica: al recircular el agua dentro del propio sistema, reduce su consumo hasta en un 90 % frente a la agricultura tradicional (Benke & Tomkins, 2017). La aeroponía lleva el principio un paso más allá y suministra los nutrientes directamente a la raíz mediante una fina nebulización.

La iluminación LED de espectro controlado completa el cuadro tecnológico. A diferencia de la luz solar, puede ajustarse a longitudes de onda específicas que favorecen el crecimiento vegetal, lo que se traduce en mayor productividad y ciclos de cultivo más cortos.

2.3.2 Modelos de producción y eficiencia

En términos productivos, la ganancia principal es la densidad de cultivo por unidad de superficie, que aumenta de forma considerable gracias a la disposición vertical de las plantas y al control de las variables ambientales, dos factores que eliminan las restricciones que normalmente impone el clima.

También permiten producir todo el año, sin las pausas que impone la estacionalidad, lo que estabiliza el suministro de alimentos. Esa ventaja pesa especialmente en las ciudades, donde la demanda de productos frescos es constante y la tierra cultivable, escasa.

Kalantari et al. (2017) calculan que la productividad por metro cuadrado puede llegar a ser entre 5 y 10 veces mayor que en la agricultura tradicional, según el cultivo y la tecnología empleada.

2.3.3 Sostenibilidad y limitaciones

Estas ventajas no vienen sin costo. El principal desafío es el consumo energético que exigen la iluminación artificial y la climatización, un gasto que puede terminar comprometiendo la sostenibilidad del sistema si la electricidad proviene de fuentes no renovables.

A eso se suman costos de instalación y operación bastante más altos que los de la agricultura convencional, lo que frena su adopción a gran escala, sobre todo en países en desarrollo.

Por eso algunos autores insisten en que la agricultura vertical solo será plenamente sostenible si se integra con energías renovables. La

combinación con sistemas fotovoltaicos, en particular, aparece como una línea de investigación con recorrido por delante.

2.4 Impacto ambiental y social de las tecnologías agrícolas

La tecnología ha transformado los sistemas productivos agrícolas de forma profunda, con consecuencias que se sienten tanto en lo ambiental como en lo social. Ofrece, sin duda, oportunidades reales para ganar eficiencia y sostenibilidad; pero también plantea desafíos que conviene mirar con una perspectiva integral, sin caer en el optimismo tecnológico fácil.



Figura 36. El agricultor en la innovación del agro.

Nota. Tomado del sitio web https://thefoodtech.com/archivo/la-importancia-de-la-produccion-agricola-sostenible/

2.4.1 Inteligencia artificial y adaptación al cambio climático

El cambio climático es, quizá, el desafío más determinante para la agricultura contemporánea. El aumento de las temperaturas globales, la mayor variabilidad en las precipitaciones y la frecuencia creciente de eventos extremos golpean directamente la productividad agrícola y la estabilidad del sistema agroalimentario.

Frente a ese panorama, la inteligencia artificial y el Big Data se han convertido en herramientas clave para fortalecer la capacidad de adaptación del sector. Al procesar grandes volúmenes de datos climáticos históricos junto con observaciones meteorológicas en tiempo real, los modelos de aprendizaje automático logran identificar patrones que anticipan eventos extremos y estiman su posible impacto sobre los cultivos (Rolnick et al., 2019).

Un ejemplo concreto son los sistemas de predicción que cruzan temperatura, humedad, radiación solar y precipitación para generar pronósticos hiperlocales, con los que el agricultor puede ajustar con más criterio sus decisiones de siembra, riego y fertilización.

Estos modelos también se aplican a la búsqueda de variedades más resistentes: al analizar grandes bases de datos genéticos y agronómicos, los algoritmos identifican combinaciones de características asociadas a una mayor tolerancia a sequías, altas temperaturas o enfermedades.

A mayor escala, la combinación de inteligencia artificial y teledetección permite monitorear extensiones agrícolas enteras y detectar, a tiempo, cambios en la productividad o en las condiciones del suelo asociados a

fenómenos climáticos extremos, una capacidad que contribuye a construir sistemas más resilientes.

2.4.2 Impacto ambiental

En el plano ambiental, el riego inteligente, las energías renovables y la agricultura de precisión han demostrado, en conjunto, que es posible optimizar el uso del agua, reducir la aplicación de agroquímicos y mejorar la eficiencia energética del sistema (Basso & Antle, 2020).

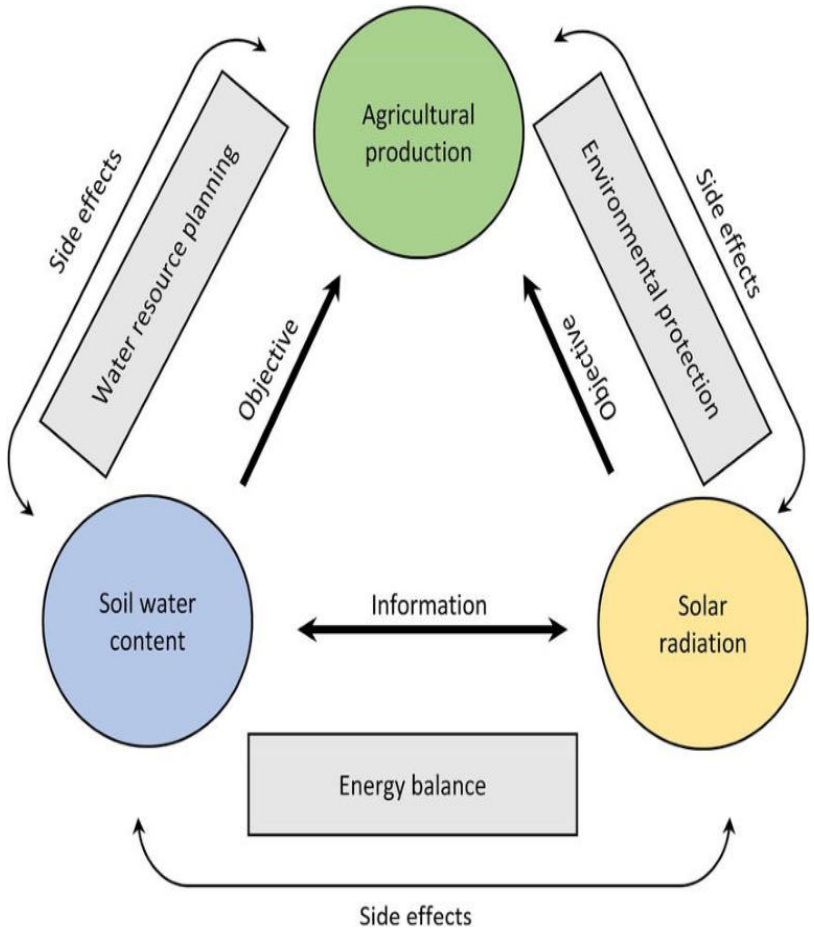


Figura 37. Diagrama de un ecosistema de producción sostenible.

Nota. De “Assessment of the water content of the soil and utilization of the energy balance model to promote environmentally friendly development of green, low-carbon industries”, por Q. Xiang, 2023, *Water Supply*, *24*(2), p. 375. https://doi.org/10.2166/ws.2023.289

Las tecnologías de aplicación variable, en particular, han logrado reducir el uso de fertilizantes y pesticidas, lo que se traduce en menos contaminación del suelo y del agua y en una mejor preservación de la biodiversidad. La incorporación de energías renovables suma su propio aporte, al reducir la dependencia de combustibles fósiles.

No todo son beneficios, sin embargo. El uso de tecnologías avanzadas también trae consigo un mayor consumo energético en los sistemas más tecnificados, genera residuos electrónicos y puede favorecer una intensificación productiva que termine afectando a los ecosistemas naturales.

Un caso ilustra bien esta tensión entre tecnología y ecosistema: la Sigatoka Negra, enfermedad causada por el hongo Mycosphaerella fijiensis Morelet y una de las más destructivas para el cultivo del banano a nivel mundial. Su impacto ha sido de tal magnitud que ha llegado a influir en dinámicas comerciales de gran escala, como la llamada «guerra bananera», que desplazó operaciones de las grandes corporaciones de Centroamérica hacia Sudamérica (Sheng & Felix do Nascimento, 2021).

La enfermedad puede reducir el peso de la fruta en más de un 50 %, acelerar su maduración y comprometer la calidad del producto hasta el punto de que lotes completos se desechen ya en su destino final; y su

control, precisamente, exige cantidades considerables de agroquímicos que terminan por vulnerar los ecosistemas circundantes (Soarez et al., 2021). El ejemplo deja una lección de fondo: ni siquiera las tecnologías más avanzadas de monitoreo eliminan por completo los efectos ambientales que buscan mitigar; en el mejor de los casos, los reducen.

2.4.3 Impacto social

En lo social, la adopción de tecnologías agrícolas ha traído oportunidades, pero también tensiones propias. Del lado positivo, mejora la productividad, incrementa los ingresos del agricultor y facilita el acceso a información en tiempo real.

Pero esa balanza entre tecnología, recursos y gestión ambiental no siempre está equilibrada, y ahí aparece uno de los problemas más persistentes del sector: la brecha digital entre grandes y pequeños productores.

Esa brecha se manifiesta en el acceso desigual a tecnología, infraestructura digital y capacitación, y termina alimentando procesos de exclusión y desigualdad dentro del propio sector agrícola (FAO, 2023).

La automatización añade otra capa de tensión: al reducir la demanda de mano de obra en ciertas actividades, afecta directamente al empleo rural. De ahí la necesidad de estrategias de reconversión laboral y formación técnica que permitan a los trabajadores adaptarse a las nuevas exigencias del sector.

2.4.4 Perspectiva crítica y sostenibilidad inclusiva

Vista con ojo crítico, la sostenibilidad de estas tecnologías no puede medirse solo en eficiencia productiva o impacto ambiental; también hay que preguntarse si generan beneficios sociales equitativos, o si terminan concentrando las ventajas en quienes ya tenían más.

Promover modelos de innovación inclusiva, que garanticen el acceso de pequeños y medianos productores a la tecnología, resulta, en ese sentido, fundamental. Eso implica políticas públicas de digitalización del sector, además de programas de capacitación y financiamiento que faciliten la adopción tecnológica.

La colaboración entre universidades, gobiernos y sector privado también resulta clave: son las soluciones adaptadas a las condiciones locales, no las importadas sin ajustes, las que terminan maximizando el impacto positivo de la tecnología en la agricultura.



Figura 38. Modelo conceptual de agricultura sostenible basada en tecnologías verdes y digitales.

Nota. Elaboración propia a partir de Basso & Antle (2020), Liakos et al. (2018) y FAO (2023).

La Figura 38 resume el argumento central de este capítulo en forma de modelo conceptual: la inteligencia artificial, el Internet de las Cosas, la teledetección y las energías renovables no operan de forma aislada, sino como facilitadores de una gestión más eficiente de los recursos agrícolas. Su interacción con los sistemas productivos es lo que permite optimizar el agua, reducir los agroquímicos y mejorar la eficiencia energética, y de ahí se derivan beneficios tanto ambientales como

sociales: menor impacto ecológico, mayor productividad y sistemas agroalimentarios más resilientes frente al cambio climático.

2.5 Desafíos y perspectivas futuras de la agricultura tecnológica

Los avances descritos en este capítulo no deben ocultar los desafíos que persisten en su implementación a gran escala: el costo inicial de las tecnologías sigue siendo alto, la infraestructura digital rural es limitada y la brecha entre grandes y pequeños productores no se ha cerrado. A esto se suma un reto más reciente: la gobernanza de los datos agrícolas, con preguntas abiertas sobre privacidad, interoperabilidad de plataformas y la falta de estándares tecnológicos comunes. De cara al futuro, es razonable esperar que la convergencia entre inteligencia artificial, Internet de las Cosas, robótica agrícola y energías renovables impulse una nueva generación de sistemas agrícolas más autónomos, resilientes y sostenibles. Que esa transición sea también inclusiva, y no solo eficiente, dependerá en gran medida de la investigación científica y de políticas públicas orientadas deliberadamente a ese propósito, con la seguridad alimentaria global y la mitigación del cambio climático como horizonte.

Facuy y Diego (2026) coinciden con este diagnóstico: los modelos predictivos basados en redes neuronales y el análisis de datos a gran escala serán, sostienen, determinantes para enfrentar los desafíos ambientales y productivos de las próximas décadas.

2.6 Gobernanza y ética de los datos agrícolas

Cuanto más se digitaliza un sistema agrícola, más crítica se vuelve la gestión de sus datos. La información que generan sensores IoT, drones,

maquinaria inteligente y plataformas de análisis se acumula de forma masiva, y con ella llegan preguntas que el sector apenas empieza a responder: ¿de quién son esos datos?, ¿quién puede usarlos?, ¿bajo qué condiciones de privacidad?

Estos datos, prácticas productivas, características del suelo, rendimiento de los cultivos, uso de insumos, estrategias de manejo, son, en sí mismos, información sensible. Sirven, sin duda, para alimentar modelos predictivos que mejoran la eficiencia productiva; pero Bronson y Knezevic (2016) advierten sobre el riesgo opuesto: que esa información termine concentrada en manos de un puñado de empresas tecnológicas.

El debate de fondo gira, precisamente, en torno a la propiedad de esos datos. El agricultor suele operar maquinaria o plataformas de empresas tecnológicas que recopilan información de forma continua durante las labores agrícolas, sin que siempre quede claro quién tiene derecho a acceder a ella, usarla o comercializarla.

Algunas organizaciones internacionales han empezado a proponer principios de gobernanza para estos datos, orientados a la transparencia, la equidad y la protección del agricultor: consentimiento informado para la recolección, interoperabilidad entre plataformas y acceso equitativo a la información generada (FAO, 2021).

Esa gobernanza pasa también por establecer estándares técnicos que permitan integrar datos de múltiples fuentes, porque sin interoperabilidad entre plataformas es difícil construir sistemas capaces de analizar la información de forma conjunta y generar recomendaciones realmente precisas.

Hay, finalmente, una pregunta ética que atraviesa todo lo anterior: si los beneficios de la digitalización agrícola se reparten de forma equitativa entre los actores del sistema. La inteligencia artificial no debería ampliar la brecha entre grandes y pequeños productores; su justificación, más bien, está en construir sistemas productivos más inclusivos y sostenibles.

2.7 Agricultura autónoma y robótica inteligente

Entre las tendencias tecnológicas del sector agropecuario, la automatización es de las que más promete. La llamada agricultura autónoma combina robótica avanzada, inteligencia artificial y sistemas de navegación automatizada para ejecutar tareas agrícolas con una intervención humana mínima.

Sus aplicaciones ya cubren buena parte del ciclo productivo: siembra automatizada, monitoreo de cultivos, control de malezas, aplicación de fertilizantes y pesticidas, e incluso cosecha selectiva de frutas y hortalizas.

Su principal ventaja es la precisión: equipados con visión artificial, estos robots identifican plantas individuales, detectan malezas o evalúan el estado de madurez de un cultivo con un nivel de detalle que el ojo humano difícilmente iguala.

Tampoco se fatigan: pueden operar durante periodos prolongados sin pausas, lo que mejora la eficiencia de las operaciones y reduce los costos laborales asociados a ciertas actividades.

Los sistemas de pulverización inteligente son, quizá, el ejemplo más elocuente: robots con cámaras y algoritmos de inteligencia artificial identifican malezas en tiempo real y aplican herbicida solo donde hace falta, lo que reduce de forma notable el uso de agroquímicos y el impacto ambiental de la agricultura intensiva (Blue River Technology, 2022).

Cuando la robótica se integra con sistemas de análisis de datos, el resultado son explotaciones agrícolas altamente automatizadas, capaces de recibir información del cultivo en tiempo real y ajustar sus operaciones según lo que recomiendan los algoritmos.

A largo plazo, la apuesta es que la agricultura autónoma ayude a enfrentar desafíos estructurales del sector: la escasez de mano de obra rural, el alza de los costos laborales y la necesidad, siempre presente, de mejorar la eficiencia productiva.

Tabla 8. Tendencias tecnológicas emergentes en la agricultura hacia 2030–2040.

Tecnología emergente	Aplicación agrícola	Beneficio esperado
Inteligencia artificial avanzada	Predicción de rendimientos y gestión automatizada de cultivos	Mayor precisión en la toma de decisiones
Robótica agrícola	Siembra, cosecha y control de malezas automatizado	Reducción de costos laborales

Agricultura de precisión basada en satélites	Monitoreo de cultivos a gran escala	Optimización de insumos agrícolas
Internet de las Cosas (IoT) agrícola	Sensores para monitoreo continuo de suelo y clima	Gestión eficiente de recursos
Energías renovables agrícolas	Energía solar y biogás para sistemas de producción	Reducción de emisiones de carbono
Agricultura vertical y urbana	Producción de alimentos en entornos urbanos	Mayor eficiencia en el uso del suelo

Nota. Elaboración propia con base en FAO (2023), Liakos et al. (2018) y Basso y Antle (2020).

La Tabla 8 deja ver el rasgo común de todas estas tendencias: el futuro de la agricultura no dependerá de una sola tecnología, sino de la convergencia entre lo digital, lo energético y lo biotecnológico. Inteligencia artificial, robótica, sensores inteligentes y energías renovables, combinados, son los que están transformando los modelos productivos tradicionales en sistemas de agricultura inteligente, capaces de optimizar los recursos naturales y sostener la producción alimentaria a largo plazo.

En conjunto, la agricultura sostenible y las tecnologías verdes ofrecen una respuesta integral a los desafíos del sistema agroalimentario global: el riego inteligente, las energías renovables y la agricultura vertical optimizan recursos, mejoran la productividad y reducen el impacto ambiental. Pero ninguna de estas tecnologías triunfa por sí sola; su éxito depende de que se adapten a contextos locales y de que existan políticas públicas que garanticen inclusión tecnológica y acceso equitativo a la innovación. El futuro de la agricultura, en última instancia, se juega en esa capacidad de integrar tecnología, sostenibilidad y equidad social en un modelo productivo a la vez resiliente y eficiente.

2.8 Conclusiones

La agricultura atraviesa un proceso de transformación que difícilmente puede entenderse únicamente como la incorporación de nuevas herramientas tecnológicas. Lo que está ocurriendo es un cambio más profundo en la manera de observar, interpretar y gestionar los sistemas productivos. A través del tiempo, una parte importante de las decisiones agrícolas dependió de la experiencia del productor y del conocimiento técnico disponible en el momento. Ese conocimiento de las técnicas sigue siendo indispensable, pero hoy en día puede complementarse con información proveniente de sensores, imágenes satelitales, drones, maquinaria inteligente, estaciones meteorológicas, dashboards y plataformas digitales. La principal diferencia está en que ahora existe la posibilidad de convertir los datos en información útil para tomar decisiones con anticipación y precisión.

A lo largo del primer capítulo se evidenció que la inteligencia artificial y el Big Data no constituyen tecnologías aisladas, sino componentes de

un ecosistema más amplio asociado con la Agricultura 4.0. Su verdadero potencial aparece cuando se integran con otras herramientas como el Internet de las Cosas, la computación en la nube, los sistemas de teledetección y la automatización. En conjunto, estas tecnologías permiten pasar de una agricultura basada principalmente en decisiones generales a otra donde es posible observar diferencias dentro de una misma parcela, anticipar determinados riesgos y administrar los recursos con un mayor nivel de detalle.

Uno de los aportes más importantes de esta transformación se encuentra en la capacidad de utilizar modelos predictivos para apoyar decisiones relacionadas con el rendimiento agrícola, el uso del agua, la fertilización y el manejo fitosanitario. Sin embargo, los resultados analizados también muestran que la inteligencia artificial no debe interpretarse como una fuente de respuestas infalibles. Los algoritmos dependen directamente de los datos utilizados para entrenarlos, de la calidad de las mediciones, del contexto agroclimático y de las condiciones en las que posteriormente serán aplicados. Un modelo que presenta buenos resultados en un entorno determinado puede perder precisión cuando cambia el cultivo, la región, la iluminación de una imagen o las condiciones ambientales.

Esta situación pudo observarse de manera particularmente clara en el caso aplicado al reconocimiento de Sigatoka Negra en el cultivo de banano. El experimento permitió comprobar que una red neuronal convolucional podía aprender características relevantes de las imágenes y alcanzar mejores resultados cuando el problema de clasificación se simplificaba. Sin embargo, también evidenció las dificultades

existentes para diferenciar con precisión seis estadios de severidad utilizando una base de datos relativamente pequeña. La reducción de seis categorías a tres y posteriormente a dos grupos produjo una mejora progresiva del comportamiento del modelo.

Más que considerar esta dificultad como un resultado negativo, puede entenderse como una de las principales enseñanzas del caso. En inteligencia artificial, aumentar la complejidad del problema no garantiza una solución más útil. En ocasiones, una clasificación menos granular puede ofrecer información más estable para apoyar una decisión concreta. En el caso estudiado, los resultados sugieren que diferenciar grupos amplios de severidad resulta considerablemente más viable que identificar visualmente cada estadio de la enfermedad. Esto también confirma la necesidad de ampliar y diversificar las bases de imágenes cuando se pretende desarrollar aplicaciones que posteriormente serán utilizadas en condiciones reales de producción.

El caso de Sigatoka Negra demuestra además la importancia de trabajar con datos locales. Muchas investigaciones de visión artificial agrícola utilizan bases construidas en entornos controlados, donde las imágenes presentan condiciones relativamente homogéneas. En campo, la realidad es distinta: la iluminación cambia, las hojas pueden presentar diferentes orientaciones, existen daños causados por otros factores y una misma enfermedad puede manifestarse de manera variable. Por ello, la construcción de una base propia de imágenes y el etiquetado de regiones de interés constituyen elementos relevantes del experimento, porque acercan el problema de clasificación a las condiciones que enfrenta realmente un sistema agrícola.

También se observa que el valor de una herramienta de inteligencia artificial no consiste necesariamente en sustituir al especialista. En aplicaciones fitosanitarias, el técnico agrícola continúa siendo fundamental para interpretar la información y tomar decisiones de manejo. La tecnología puede facilitar la captura de datos, realizar una clasificación preliminar, identificar zonas que requieren atención o permitir un seguimiento más frecuente. Desde esta perspectiva, resulta más adecuado hablar de sistemas de apoyo a la decisión que de sistemas destinados a reemplazar la experiencia profesional.

Otro aspecto central desarrollado en el libro es que la digitalización agrícola solo tiene sentido si contribuye a resolver problemas productivos concretos. La posibilidad de instalar sensores, utilizar drones o incorporar algoritmos sofisticados no constituye por sí misma una mejora. La innovación tiene valor cuando logra reducir pérdidas, utilizar mejor los recursos, disminuir costos o aumentar la capacidad de respuesta ante un riesgo. Esta idea resulta especialmente importante en contextos donde los productores disponen de recursos económicos limitados y donde una solución excesivamente compleja puede resultar tecnológicamente atractiva, pero prácticamente inaccesible.

El segundo capítulo permite ampliar esta discusión al mostrar que el futuro de la agricultura no depende exclusivamente de la inteligencia artificial. La sostenibilidad exige analizar también la manera en que se utilizan recursos básicos como el agua y la energía. Los sistemas de riego inteligente representan un ejemplo claro de esta relación entre digitalización y sostenibilidad, ya que combinan información obtenida mediante sensores con modelos de análisis que permiten ajustar las

decisiones de riego a las condiciones reales del suelo, del clima y del cultivo.

La misma lógica se observa en la incorporación de fuentes renovables de energía. La utilización de sistemas fotovoltaicos en actividades agrícolas y el aprovechamiento de residuos orgánicos mediante biogás demuestran que la innovación tecnológica puede contribuir simultáneamente a disminuir costos energéticos y reducir determinados impactos ambientales. Estas soluciones adquieren especial importancia en zonas rurales donde el acceso a fuentes convencionales de energía puede ser limitado o costoso.

Por otra parte, la agricultura vertical y los sistemas de cultivo en ambientes controlados muestran hasta dónde puede llegar la transformación del modelo productivo. La posibilidad de controlar variables como iluminación, nutrientes, temperatura y disponibilidad de agua permite independizar parcialmente la producción de las condiciones climáticas externas. No obstante, estas tecnologías presentan limitaciones relacionadas con sus costos de implementación y su consumo energético, lo que obliga a evaluar su sostenibilidad de manera integral. Una tecnología no puede considerarse sostenible únicamente porque utiliza menos agua o menos suelo; también deben analizarse la energía que requiere, los materiales empleados y su viabilidad económica.

Esta mirada crítica debe extenderse a todas las tecnologías analizadas. La inteligencia artificial puede contribuir a reducir insumos, pero también necesita infraestructura computacional. Los sensores permiten

producir información de manera continua, pero generan nuevos requerimientos de conectividad y mantenimiento. La automatización puede aumentar la productividad, pero también modifica las necesidades de mano de obra y exige nuevas competencias. Por ello, la transformación digital del agro debe evaluarse considerando simultáneamente sus dimensiones productivas, ambientales, económicas y sociales.

Uno de los desafíos más importantes será evitar que la agricultura digital profundice las diferencias existentes entre productores. Las grandes explotaciones suelen disponer de mayores recursos para adquirir sensores, maquinaria automatizada, plataformas de gestión o servicios especializados. Los pequeños productores, en cambio, pueden encontrar barreras relacionadas con costos, conectividad, capacitación y acceso a información. Si estas diferencias no son consideradas, existe el riesgo de que la innovación tecnológica mejore la eficiencia general del sector mientras aumenta la desigualdad dentro de él.

En este sentido, las universidades, los centros de investigación, los gobiernos y el sector privado tienen un papel fundamental. La transferencia tecnológica no puede reducirse a presentar nuevas herramientas; debe incluir formación, adaptación de las soluciones a las condiciones locales y acompañamiento a los usuarios. También resulta necesario fomentar el desarrollo de tecnologías que puedan funcionar con infraestructura limitada y costos razonables, especialmente en regiones donde predominan pequeños y medianos productores.

La gobernanza de los datos constituye otro desafío que adquirirá cada vez mayor importancia. A medida que la producción agrícola depende de plataformas digitales, sensores y maquinaria conectada, se genera información detallada sobre rendimientos, características del suelo, utilización de insumos y estrategias productivas. Estos datos tienen valor económico y estratégico. Por ello, cuestiones relacionadas con su propiedad, privacidad, almacenamiento y utilización no deben considerarse problemas secundarios. Una agricultura basada en datos requiere también reglas claras sobre quién puede acceder a esa información y con qué finalidad.

Finalmente, la agricultura del futuro probablemente será más automatizada, más conectada y más intensiva en información, pero eso no significa necesariamente que será completamente autónoma. Los robots agrícolas, los sistemas de visión artificial y los modelos predictivos seguirán necesitando objetivos definidos por personas, datos correctamente interpretados y decisiones adaptadas a contextos productivos específicos. La tecnología puede aumentar significativamente la capacidad de observar y analizar el entorno, pero el conocimiento agronómico y la experiencia humana continúan siendo elementos centrales del proceso.

El principal aprendizaje que deja el análisis desarrollado en esta obra es que la verdadera innovación agrícola no consiste en incorporar la mayor cantidad posible de tecnología. Consiste en utilizar la tecnología adecuada para resolver el problema adecuado. Un sensor tiene valor cuando genera información útil; un modelo de inteligencia artificial tiene valor cuando ayuda a tomar una mejor decisión; un robot tiene

valor cuando realiza una tarea de manera más eficiente; y una fuente de energía renovable tiene valor cuando contribuye a que el sistema productivo sea económica y ambientalmente sostenible.

Por ello, el futuro de la agricultura no debe plantearse como una elección entre tecnología y conocimiento tradicional, ni entre productividad y sostenibilidad. El desafío está precisamente en integrar esos elementos. La experiencia del agricultor, el conocimiento técnico, los datos, los algoritmos y las tecnologías verdes pueden complementarse para construir sistemas productivos capaces de responder a escenarios cada vez más complejos.

En última instancia, la inteligencia artificial, el Big Data, la robótica o el Internet de las Cosas son herramientas. Su impacto dependerá de la forma en que sean diseñadas, utilizadas y puestas al servicio de las necesidades reales del sector agrícola. Si esta integración se realiza con criterios de eficiencia, sostenibilidad e inclusión, la transformación tecnológica puede convertirse en una oportunidad para producir mejor, utilizar responsablemente los recursos y fortalecer la capacidad de los sistemas agroalimentarios para enfrentar los desafíos de las próximas décadas.

2.9 Anexos

2.9.1 Anexo A

RED NEURONAL PARA EL RECONOCIMIENTO DE SIGATOKA NEGRA EN EL CULTIVO DE BANANO

Entrevista 1

Expertos

Ph. D. Abraham Cervantes

Ing. Luis Pineda

Preguntas

- ¿Qué tan peligrosa considera la enfermedad de la Sigatoka Negra?
- ¿Considera que en su sector está controlada la Sigatoka Negra?
- ¿Es costoso controlar la enfermedad?
- ¿Considera que es sencillo detectar para el ojo inexperto el estadio en el que se encuentra la sigatoka?
- ¿Considera importante que los obreros de campo detecten tempranamente el estadio de la Sigatoka?
- ¿Considera que es eficiente el sistema de manejo agrícola de la sigatoka en su área de influencia?

- ¿Considera necesario un aplicativo móvil para identificar el estadio de la enfermedad?

2.9.2 Anexo B

RED NEURONAL PARA EL RECONOCIMIENTO DE SIGATOKA NEGRA EN EL CULTIVO DE BANANO

Entrevista 2

Dirigido a personal de campo y obreros de mandos medios

Preguntas

- ¿Comprende usted sobre controles fitosanitarios de la Sigatoka Negra?

- ¿Cómo influencia en su economía el avance de la Sigatoka?

- ¿Considera usted que se realiza un eficiente control de la enfermedad en su área de incidencia?

- ¿Cómo considera su capacidad para detectar el estadio en que esta la Sigatoka?

- ¿Considera necesario un aplicativo móvil para identificar el estadio de la enfermedad?

- ¿Qué tan hábil se considera en el manejo de apps móviles?

BIBLIOGRAFÍA

AgriBIT. (2022). *AgriBIT: Precision agriculture services using artificial intelligence and remote sensing*. European Union Project Report.

Agrosmart. (2020). *Smart agriculture platform for irrigation and crop monitoring*. https://agrosmart.com

Ahmad, A., Saraswat, D., & El Gamal, A. (2026). A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. *Smart Agricultural Technology*. https://doi.org/https://doi.org/10.1016/j.atech.2022.100083

AKADEMIYA2063. (2023). *Africa Agriculture Watch (AAgWa): Monitoring agricultural production in Africa*. https://www.akademiya2063.org

Amara, J., Bouaziz, B., & Algergawy, A. (2017). A deep learning-based approach for banana leaf diseases classification. *Lecture Notes in Informatics*, 79.

Basso, B., & Antle, J. (2020). Digital agriculture to design sustainable agricultural systems. *Nature Sustainability, 3*, 254–256. https://doi.org/10.1038/s41893-020-0510-0

Bayer. (2021). *Climate FieldView digital agriculture platform*. Bayer Crop Science. https://climatefieldview.com

Benke, K., & Tomkins, B. (2017). Future food-production systems: Vertical farming and controlled-environment agriculture. *Sustainability: Science, Practice and Policy, 13*(1), 13–26. https://doi.org/10.1080/15487733.2017.1394054

Bhuiyan, M., Abdullah, H., Arman, S., Rahman, S., & Al Mahmud, K. (2023). BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases. *Smart Agricultural Technology*. https://doi.org/https://doi.org/10.1016/j.atech.2023.100214

Blue River Technology. (2022). *See & Spray precision agriculture technology*. John Deere Company.

Bock, C. H., Barbedo, J. G. A., Del Ponte, E. M., Bohnenkamp, D., & Mahlein, A. K. (2020). From visual estimates to fully automated sensor-based measurements of plant disease severity. *Phytopathology Research, 2*(1). https://doi.org/10.1186/s42483-020-00050-9

Bronson, K., & Knezevic, I. (2016). Big data in food and agriculture. *Big Data & Society, 3*(1). https://doi.org/10.1177/2053951716648174

Churchill, A. (2011). Mycosphaerella fijiensis, the black leaf streak pathogen of banana: Progress towards understanding pathogen biology and detection, disease development, and the challenges of control. *Molecular Plant Pathology*, 307–328.

https://doi.org/ https://doi.org/10.1111/j.1364-3703.2010.00672.x

Climate Corporation. (2022). *Climate FieldView digital farming platform*. https://climate.com

Dahane, A., Benameur, R., & Kechar, B. (2022). An IoT low-cost smart farming for enhancing irrigation efficiency of smallholder farmers. *Wireless Personal Communications*. https://doi.org/10.1007/s11277-022-09915-4

Deere, J. (2022). *John Deere S7 combine harvester technology overview*. Deere & Company.

Duckett, T., Pearson, S., Blackmore, S., & Grieve, B. (2018). *Agricultural robotics: The future of robotic agriculture*. UK-RAS White Papers.

Escudero, C., Calvo, A., & Bejarano, A. (2022). Black Sigatoka classification using convolutional neural networks. *International Journal of Machine Learning and Computing*. https://doi.org/doi: 10.18178/ijmlc.2022.12.4.1089

Facuy, J., & Diego, A. (2026). Bridging computational power and environmental challenges: A perspective on neural network predictive models for environmental engineering. *Frontiers in Artificial Intelligence, 8*. https://doi.org/10.3389/frai.2025.1708369

Facuy Delgado, J., & Arcos-Jacome, D. (2026). Emergent language among AI agents: A path toward energy efficiency and water conservation. *Frontiers in Sustainability, 6*, 1717425. https://doi.org/10.3389/frsus.2025.1717425

Facuy Delgado, J., Yerovi Ricaurte, E. J., & Molina Oleas, W. O. (2025). Estimación cuantitativa de residuos electrónicos con técnicas de aprendizaje estadístico: Validación de un modelo XGBoost para Guayaquil. *Revista Ingenio Global, 4*(2), 25–51. https://doi.org/10.62943/rig.v4n2.2025.319

Facuy-Delgado, J., Molina-Oleas, W., & Ortega-Ponce, L. (2022). Revisión sistemática de los algoritmos para detección de enfermedades fúngicas en el arroz. *MQRInvestigar, 6*(4), 608–620. https://doi.org/10.56048/MQR20225.6.4.2022.608-620

FAO. (2000). *Panorama general de la producción y el comercio mundial de banano*. FAO. https://www.fao.org/3/y5102s/y5102s04.htm

FAO. (2019). *The state of food and agriculture*. Food and Agriculture Organization of the United Nations.

FAO. (2021). *Digital agriculture and data governance*. Food and Agriculture Organization of the United Nations.

FAO. (2022). *The future of food and agriculture: Drivers and triggers for transformation*. Food and Agriculture Organization of the United Nations.

FAO. (2023). *Digital technologies in agriculture and rural areas*. Food and Agriculture Organization of the United Nations.

Farmonaut. (2023). *AI-based satellite crop monitoring platform*. https://farmonaut.com

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture, 145*, 311–318. https://doi.org/10.1016/j.compag.2018.01.009

Gamez, M. (17 de 09 de 2015). *Objetivos y metas de desarrollo sostenible*. Desarrollo Sostenible. https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/

Gomez Selvaraj, M., Vergara, A., Ruiz, H., Safary, N., Sivalingam, E., Ocimati, W., & Blomme, G. (2019). AI-powered banana diseases and pest detection. *Plant Methods*, 92. https://doi.org/https://doi.org/10.1186/s13007-019-0475-z

Gomez Selvaraj, M., Vergara, A., Montenegro, F., Alonso Ruiz, H., Safary, N., Raymaekers, D., Ocimaty, W., Ntamwira, J., Tits, L., Bonaventure Omondi, A., & Blomme, G. (2020). Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 110–124. https://doi.org/https://doi.org/10.1016/j.isprsjprs.2020.08.025

ICRISAT. (2022). *AI-based sowing advisory system for groundnut farmers in Andhra Pradesh*. International Crops Research Institute for the Semi-Arid Tropics.

IBM. (2021). *IBM Watson Decision Platform for Agriculture*. IBM Corporation.

Jiang, Y., & Li, C. (2020). Convolutional neural networks for image-based high-throughput plant phenotyping: A review. *Plant Phenomics*, 22. https://doi.org/DOI: 10.34133/2020/4152816

Johnson, M., Smith, L., & Brown, T. (2023). Hybrid crop yield prediction models integrating APSIM and machine learning techniques. *Agricultural Systems*.

Kaiming, H., Xiangyu, Z., Shaoking, R., & Jian, S. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.

Kalantari, F., Mohd Tahir, O., Joni, R. A., & Fatemi, E. (2017). Opportunities and challenges in sustainability of vertical farming. *Journal of Landscape Ecology, 11*(1), 35–60.

Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture, 143*, 23–37. https://doi.org/10.1016/j.compag.2017.09.037

Khan, S., et al. (2024). Future of sustainable farming: Exploring opportunities and overcoming barriers in drone-IoT integration. *Discover Sustainability, 5*(1). https://doi.org/10.1007/s43621024-00736-y

Kitchenham, B., Brereton, O., Budgen, D., Turner, M., Bailey, J., & Linkman, S. (2009). Systematic literature reviews in software engineering – A systematic literature review. *Information and Software Technology*, 7–15. https://doi.org/https://doi.org/10.1016/j.infsof.2008.09.009

Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 84–90. https://doi.org/https://doi.org/10.1145/3065386

Kshetri, N. (2021). Blockchain and sustainable supply chains in agriculture. *IT Professional, 23*(2), 12–18.

Kumar, R., Singh, S., & Sharma, A. (2023). Artificial intelligence and smart farming technologies for sustainable agriculture. *Agriculture, 13*(4).

Leiva-Mora, M., Alvarado Capo, Y., Acosta, M., Cruz-Martin, M., Sanchez-Garcia, C., & Roque, B. (2010). Protocolo para la inoculación artificial de plantas de *Musa* spp. con *Mycosphaerella fijiensis* y evaluación de su respuesta mediante variables epifitiológicas y componentes de la resistencia. *Biotecnología Vegetal*.

Liakos, K., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors, 18*(8), 2674. https://doi.org/10.3390/s18082674

Liu, J., & Xuewei, W. (2021). Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17–22. https://doi.org/DOI:10.1186/s13007-021-00722-9

Liu, Y., Wang, L., & Zhang, Y. (2022). Machine learning approaches for crop yield prediction: A comparative study. *Agricultural Informatics Journal*.

Mahlein, A. K., Kuska, M. T., Thomas, S., & Wahabzada, M. (2018). Hyperspectral imaging for plant disease detection. *Plant Methods, 14*(1).

Maimaitijiang, M., et al. (2020). Soybean yield prediction from UAV multispectral imagery using deep learning. *Remote Sensing of Environment, 237*.

Manzo-Sánchez, G., Orozco-Santos, M., Martínez-Bolaños, L., Garrido-Ramírez, E., & Canto-Canche, B. (2016). Enfermedades de importancia cuarentenaria y económica del cultivo de banano (*Musa* sp.) en México. *Revista Mexicana de Fitopatología*.

Mendes, J., Pinho, T., Neves Do Santos, F., Sousa, J., Peres, E., Boaventura-Cunha, J., Cunha, M., & Morais, R. (2020). Smartphone applications targeting precision agriculture practices,A systematic review. *Agronomy*. https://doi.org/doi.org/10.3390/agronomy10060855

Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science, 7*. https://doi.org/10.3389/fpls.2016.01419

Naranjo-Torres, J., Mora, M., Hernández-Garcia, R., Barrientos, R., Fredes, C., & Valenzuela, A. (2020). A review of convolutional neural network applied to fruit image processing. *Applied Science*. https://doi.org/10.3390/app10103443

Nelson, S. C., et al. (2017). Integrated pest information platform for extension and education (iPiPE). *Plant Health Progress*.

Ngugi, L., Abelwahab, M., & Abo-Zahad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 27–51. https://doi.org/https://doi.org/10.1016/j.inpa.2020.04.004

Pieters, J., et al. (2021). Precision agriculture technologies for disease management in potato crops. *Agronomy*.

Pretty, J., Benton, T., Bharucha, Z., Dicks, L., Flora, C., Godfray, H., Goulson, D., Hartley, S., Lampkin, N., Morris, C., Pierzynski, G., Prasad, P., Reganold, J., Rockström, J., Smith, P., Thorne, P., & Wratten, S. (2018). Global assessment of agricultural system redesign for sustainable intensification. *Nature Sustainability, 1*, 441–446.

Ramesh, S., et al. (2022). IoT-based smart pest monitoring systems in agriculture. *Sensors, 22*.

Robotnik. (31 de 01 de 2022). *Application of robotics in agriculture*. Robotnik. https://robotnik.eu/robotics-applications-in-agriculture/

Rolnick, D., et al. (2019). Tackling climate change with machine learning. *Nature Climate Change, 9*, 513–517.

Saleem, M., Potgieter, J., & Arif, K. (2019). Plant disease detection and classification by deep learning. *Plants*, 468.

Sánchez-Molina, J. A., et al. (2021). Smart greenhouse systems based on IoT and artificial intelligence. *Computers and Electronics in Agriculture*.

Sharma, A., Jain, A., Gupta, P., & Clowdary, V. (2020). Machine learning applications for precision agriculture: A comprehensive review. *IEEE Access, 9*, 4843–4873. https://doi.org/10.1109/ACCESS.2020.3048415

Sheng, L., & Felix do Nascimento, D. (2021). A brief history of trade wars. In *Love and Trade War*. Palgrave Macmillan. https://doi.org/ https://doi.org/10.1007/978-981-33-4897-4_1

Singh, A., et al. (2022). Smart irrigation systems based on machine learning. *Agricultural Water Management*.

Soarez, J., Rocha, A., Nacimento, F., Miller, R., Ferreira, C., Haddad, F., Amorim, V., & Amorim, E. (2021). Genetic improvement for resistance to Black Sigatoka in bananas: A systematic review.

Frontiers in Plant Science. https://doi.org/doi.org/10.3389/fpls.2021.657916

Tao, F., Zhang, H., Liu, A., & Nee, A. (2019). Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics, 15*(4).

Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. (2017). Big data in smart farming: A review. *Agricultural Systems, 153*, 69–80. https://doi.org/10.1016/j.agsy.2017.01.023

Yan Zhang, J., MIngqu, F., & Zheng, Y. (2018). Deep indicator for fine-grained classification of banana's ripening stages. *EURASIP Journal on Image and Video Processing*. https://doi.org/https://doi.org/10.1186/s13640-018-0284-8

Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture. *Precision Agriculture, 13*, 693–712.

Zhang, Y., Wang, G., & Liu, J. (2019). Precision agriculture technologies based on IoT and AI. *Computers and Electronics in Agriculture*.

Zhao, Y., Li, X., & Zhang, Q. (2022). Deep learning approaches for crop yield prediction. *Agricultural Systems*.

Inteligencia Artificial y Big Data en la Agricultura, se publicó en el mes de noviembre de 2026.

ISBN: 978-9907-802-63-4

Grupo Editorial BLR
Ecuador
Cel: +593 98 320 4362
https://grupoblr.com/
publicaciones@grupoblr.com

BIOGRAFÍA DE AUTORES

Wilmer Henry Illescas Espinoza:
Académico e investigador ecuatoriano, vinculado a la Universidad Técnica de Machala. Es ingeniero en Administración de Sistemas, licenciado en Ciencias de la Educación y máster en Administración de Empresas. Ha desarrollado docencia e investigación universitaria, especialmente en tecnología, gestión, turismo, transformación digital y educación aplicada. Autor de Libros y de Artículos Científicos.

Jussen Facuy Delgado:
Investigador y docente ecuatoriano con un PhD en Educación . Es profesor en la Universidad de Guayaquil y en la Universidad Agraria del Ecuador e investigador en la Universidad Nacional de La Plata Su trabajo se centra en inteligencia artificial, modelos predictivos y sostenibilidad, con publicaciones sobre autismo y chatarra electrónica

Mónica Alexandra Nugra Betancourth:
Investigador y docente ecuatoriano con un PhD en Turismo, Postdoctota y Doctorante en Matemáticas y Estadística Aplicada . Es profesor en la Universidad Técnica de Machala, su trayectoria académica es enfocada en turismo, desarrollo territorial, innovación educativa, transformación digital. Autora de artículos científicos y libros, participa activamente en investigación y formación universitaria

INTELIGENCIA ARTIFICIAL Y BIG DATA EN LA AGRICULTURA

Estimado lector, este libro analiza la transformación tecnológica del sector agrícola ante los desafíos de la seguridad alimentaria, el cambio climático y la degradación de los recursos naturales, abordando la convergencia entre la agronomía y herramientas de la Agricultura 4.0 como la inteligencia artificial, el Big Data y el Internet de las Cosas. Lejos de proponer la tecnología como un sustituto del criterio humano, la obra postula el uso de estas herramientas para transformar flujos masivos de datos agronómicos en información útil para optimizar la toma de decisiones.

A través de un enfoque crítico y aplicado, el texto desmitifica el tecno-optimismo reconociendo fallos instrumentales, brechas digitales rurales y problemas éticos de gobernanza de datos. En el ámbito del diagnóstico fitosanitario, examina el empleo de visión artificial y redes neuronales convolucionales mediante un caso experimental de detección de Sigatoka Negra en banano utilizando la arquitectura ResNet18, evidenciando las complejidades de clasificación en condiciones reales de campo.

Asimismo, la obra integra la sostenibilidad ambiental como eje complementario, evaluando el riego inteligente, la agricultura vertical, las energías renovables (solar y biogás) y la robótica agrícola para reducir el uso de insumos y preservar el suelo y el agua. En conjunto, el libro ofrece una guía rigurosa orientada a articular innovación técnica, accesibilidad social y sostenibilidad productiva.

.

GRUPO BLR

Grupo Editorial BLR
Ecuador
Cel: +593 98 320 4362
https://grupoblr.com/
publicaciones@grupoblr.com

ISBN: 978-9907-802-63-4