



INTELIGENCIA ARTIFICIAL PARA EL SECTOR SILVOAGROPECUARIO: PANORAMA CIENTÍFICO

Septiembre 2024

Título

"Inteligencia Artificial para el Sector Silvoagropecuario: Panorama Científico"

Fundación para la Innovación Agraria (FIA)

Santiago, Chile

Septiembre de 2024

RPI Inscripción N°: 2024-A-9421

Elaboración Técnica

El estudio de Vigilancia Tecnológica e Inteligencia competitiva en "Inteligencia Artificial para el sector Silvoagropecuario", fue desarrollado por IALE Tecnología Chile SpA, por encargo de la Fundación para la Innovación Agraria (FIA), para promover las nuevas tecnologías en sectores agropecuario, agroalimentario y forestal como estrategia de agricultura sustentable.

IALE Tecnología Chile SpA, contribuye con la metodología de vigilancia tecnológica e inteligencia competitiva, a recopilar información desde fuentes relacionadas con el área de estudio, para su posterior análisis y consolidación de los informes del estudio de Vigilancia Tecnológica e Inteligencia Competitiva, compuesto por: Panorama Científico, Panorama Tecnológico y Panorama de Mercado.

Autores

Directora: Ivette Ortiz Montenegro

Ingenieros: Jorge Córdova Añasco y Valentina Browne López

Experto: Werner Creixell Fuentes

Revisión, supervisión y edición FIA

Marcelo Canepa Guerra

Marcela González Pérez

Andrea Jofré Soto

Fotografía:

elements.envato.com

istockphoto.com

Diseño Gráfico:

Flavia Perazzo Ortiz

PRESENTACIÓN



La inteligencia artificial (IA) ha revolucionado la sociedad moderna, transformando desde procesos productivos hasta la forma en que interactuamos con el mundo. En este contexto de constante evolución, el presente estudio de Vigilancia Tecnológica e Inteligencia Competitiva en Inteligencia Artificial para el sector Silvoagropecuario se presenta como una herramienta clave para comprender y aprovechar el potencial de esta tecnología en un sector esencial como lo es el silvoagropecuario.

Este estudio aborda dos pilares fundamentales:

1. Análisis de Vigilancia Tecnológica: Una descripción exhaustiva de las tendencias actuales, las principales líneas de investigación, las tecnologías emergentes y los actores clave, tanto a nivel nacional como internacional. Esta información se presenta en el Panorama Científico y en el Panorama Tecnológico.
2. Análisis de Inteligencia Competitiva: Un estudio enfocado en identificar las tendencias del mercado, los desarrollos de mayor relevancia comercial y los productos y proveedores más destacados. Esta información se presenta en el Panorama de Mercado.

La IA ha experimentado un crecimiento explosivo en aplicaciones y usos en diversos ámbitos, consolidándose como una tecnología de propósito general. Tal como la imprenta, la electricidad o las tecnologías de la información marcaron hitos históricos, la IA tiene el potencial de revolucionar las sociedades contemporáneas. Especialmente con el advenimiento de la Inteligencia Artificial Generativa (como *ChatGPT*, *Google Gemini*, *Microsoft Copilot*, *Claude* entre otras), se evidencian transformaciones significativas en múltiples sectores, afectando incluso ocupaciones de alto ingreso, como sugieren estudios recientes.

Este Estudio no solo proporciona herramientas para entender el estado actual y el futuro de la IA en el sector silvoagropecuario, sino que también habilita a sus lectores para tomar decisiones informadas en un entorno cada vez más dinámico y competitivo.

Una lectura imprescindible para investigadores, productores, empresarios y tomadores de decisiones interesados en liderar el cambio tecnológico en un sector vital para el desarrollo sostenible.

Francine Brossard Leiva
Directora Ejecutiva
Fundación para la Innovación Agraria



OBJETIVOS

Objetivo general

Realizar un estudio de Vigilancia Tecnológica e Inteligencia Competitiva para identificar y analizar el desarrollo de la Inteligencia Artificial, IA aplicada al sector Silvoagropecuario.

Objetivos específicos

- ➔ Identificar, analizar, caracterizar y sistematizar el conocimiento científico que se está publicando a nivel mundial que permita conocer la frontera del conocimiento.
- ➔ Identificar, caracterizar y sistematizar las tecnologías que se están protegiendo, los proyectos que se están desarrollando así como las iniciativas en políticas públicas en torno a la IA a nivel internacional y nacional.
- ➔ Identificar las tendencias de mercado, nuevos desarrollos, nuevas empresas-proveedoras y oferta comercial nacional e internacional.

CONTENIDO



0. Antecedentes.....04

1. Panorama general.....05

- 1.1 Inteligencia artificial.....05
 - 1.1.1 ¿Qué es la IA?.....05
 - 1.1.2 ¿Cómo aprenden los algoritmos de IA?.....07
- 1.2 Inteligencia Artificial en el sector Silvoagropecuario.....08

2. Panorama científico.....11

- 2.1 Evolución de la producción científica.....11
- 2.2 Identificación de actores líderes.....12
 - 2.2.1 Principales países.....12
 - 2.2.2 Principales instituciones.....15
 - 2.2.3 Principales autores.....17
- 2.3 Líneas de investigación.....20
 - 2.3.1 AGRICULTURA.....20
 - 2.3.2 GANADERÍA.....26
 - 2.3.3 SILVICULTURA.....29
 - 2.3.4 FLORICULTURA.....33

3. Conclusiones.....35

4. Bibliografía.....37

0. Antecedentes

Se presenta el estudio de Vigilancia Tecnológica e Inteligencia Competitiva en “Inteligencia Artificial para el sector Silvoagropecuario”. Específicamente, el objetivo planteado busca lo siguiente:

- Desarrollar un análisis de vigilancia tecnológica que describa las tendencias, líneas de investigación, tecnologías emergentes y los actores principales a nivel nacional e internacional.
- Desarrollar un análisis de inteligencia competitiva que identifique la tendencia de mercado de los nuevos desarrollos, identifique productos y proveedores de interés comercial.

Se aplicará la metodología de Vigilancia Tecnológica clásica que consiste en la búsqueda, captura y análisis de información contenida en bases de datos internacionales, generando con ello una caracterización en términos de líneas de investigación y tecnologías en desarrollo, principales actores (instituciones, empresas, países), entre otros. En este sentido y como primera instancia del proceso metodológico, se definen las palabras claves, las fuentes de información y las ecuaciones de búsqueda que permiten encontrar todas las necesidades de información requeridas.

Una vez acotados los resultados de las búsquedas se inicia la fase de pretratamiento del corpus de información, que consiste en preparar las condiciones impuestas por las herramientas de análisis. A partir de los datos entregados por las diferentes bases de datos, se realiza un proceso de depuración y afinación del corpus de información, para dar paso a la fase de procesamiento/análisis. Para la fase de procesamiento y análisis cuantitativo de la información, el equipo consultor se apoyará en herramientas de minería de datos. Los resultados del análisis cuantitativo y cualitativo de la información se estructurarán en 3 capítulos:

- El capítulo 1 contendrá una descripción del contexto general del estudio, en este caso, Inteligencia Artificial, qué es, cómo aprenden los algoritmos de IA y su aplicación al sector Agropecuario.
- El capítulo 2 contendrá los resultados del panorama científico para el período 2019-2023, en términos de la evolución en el nivel de publicaciones científicas, actores líderes como países, instituciones e investigadores y las líneas de investigación específicas que surgen de estas investigaciones en agricultura, ganadería, floricultura y silvicultura.
- El capítulo 3 mostrará además de los resultados internacionales en cuanto a líderes y actores claves, los hallazgos nacionales de IA en agricultura y el tipo de aprendizaje supervisado que se requiere.

1. Panorama General

1.1 Inteligencia Artificial

La inteligencia Artificial en el último tiempo ha experimentado un explosivo aumento en la cantidad de usos y aplicaciones en los más variados ámbitos del quehacer de la sociedad. Es difícil imaginar un área, actividad o aspecto de la sociedad que no esté siendo, o que, en el futuro cercano, no sea transformado por esta disciplina. Es más, esta disciplina se perfila para transformarse en una tecnología de propósito general [1] con la capacidad transformadora que en su momento tuvieron la imprenta, la máquina a vapor, la electricidad o las tecnologías de la información. En efecto, la IA presenta todo el potencial para revolucionar la sociedad y sus procesos productivos. Con el advenimiento de la Inteligencia Artificial Generativa (AGI), en particular Chat GPT, esta situación se hace más evidente, según el 80% de los trabajos en EE. UU. verán al menos un 10% de sus tareas afectadas por la irrupción de Chat GPT. Y a diferencia de las olas previas de automatización, donde los trabajos más afectados fueron aquellos de menor remuneración, en esta ocasión los más afectados serían las ocupaciones de mayor ingreso [2]. Sin embargo, el conocimiento sobre la IA suele llegar cubierto por especulaciones y convicciones, que en muchos casos poco, o nada, tienen que ver con la realidad y desarrollo de esta tecnología. Este primer capítulo pretende dar respuesta a preguntas como: ¿Qué es la IA? ¿Cómo aprenden los algoritmos? ¿Cómo es posible clasificar las diferentes técnicas que la componen? ¿Qué es necesario para utilizar estas técnicas? ¿Cuándo es posible considerar un método o algoritmo como IA?



1.1.1 ¿Qué es la IA?

La inteligencia artificial (IA) es un campo de la informática y la ingeniería que se centra en la creación de sistemas capaces de realizar tareas que normalmente requieren inteligencia humana. Estas tareas incluyen el aprendizaje, el razonamiento, la percepción, la toma de decisiones y la adaptación a nuevas situaciones. A diferencia de los programas de computadora tradicionales, que siguen instrucciones explícitas, la IA utiliza algoritmos que permiten a las máquinas aprender de los datos y la experiencia, mejorando su rendimiento con el tiempo.

En la figura 1.1, se muestra una comparación de cómo operan los algoritmos tradicionales en los que el usuario debe proveer los datos y las reglas que el algoritmo debe seguir para obtener los resultados deseados. Los algoritmos de IA, en cambio, reciben como entrada datos y resultados (experiencias anteriores) para que éstos aprendan las reglas necesarias para procesar datos en el futuro. Los algoritmos de IA, por lo tanto, difieren fundamentalmente de los tradicionales en cuanto a que su salida no está determinada por el programador sino por las características de los pares (datos, resultados) provistos durante el aprendizaje. Este paradigma es conocido como aprendizaje supervisado y es una de las formas en que los algoritmos de IA aprenden.



Figura 1.1: Comparación de cómo operan los algoritmos tradicionales v/s los que usan IA. Fuente: Creixell W., 2023

En este estudio el foco estará en las diferentes formas de aprendizaje como taxonomía de IA. Es importante señalar que no existe una taxonomía única y universalmente aceptada. Tal taxonomía está presentada en la figura 1.2.

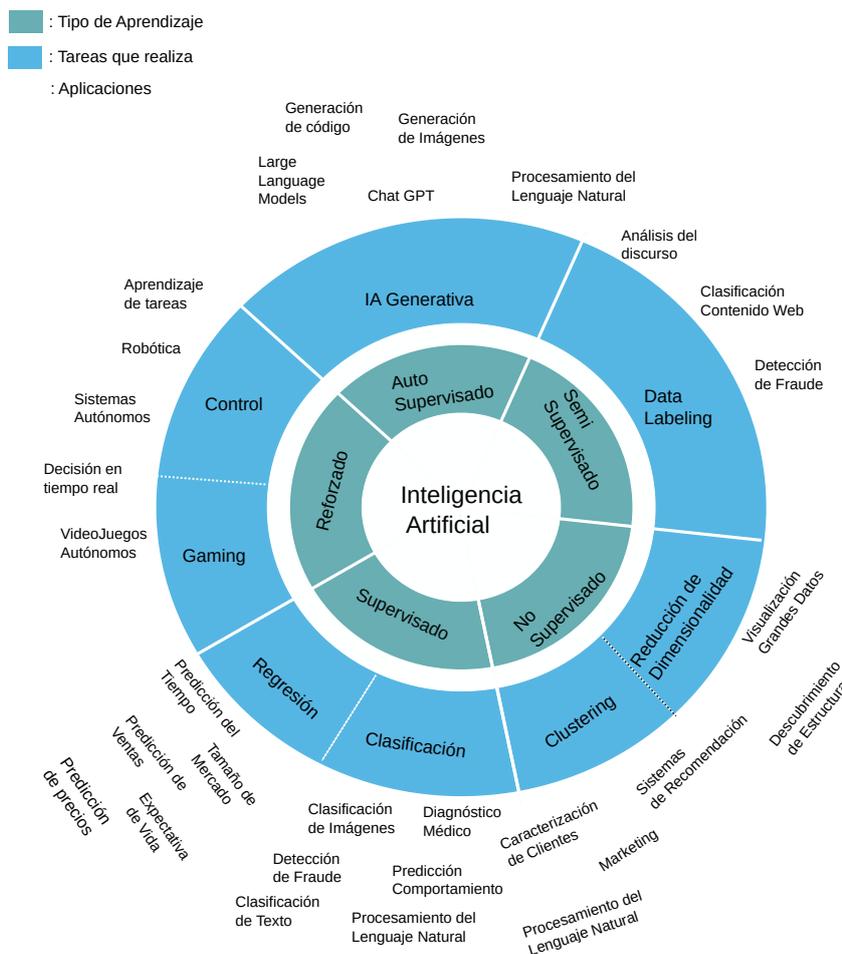


Figura 1.2: Taxonomía de IA basada en aprendizaje. Fuente: Creixell W., 2023

1.1.2 ¿Cómo aprenden los algoritmos de IA?

Aprendizaje Supervisado: El aprendizaje supervisado es una categoría principal del aprendizaje automático que implica entrenar un modelo utilizando un conjunto de datos etiquetados (pares datos-resultados). En este enfoque, el algoritmo recibe un conjunto de entradas junto con las salidas correspondientes y aprende a mapear estas entradas a salidas. Durante el entrenamiento, el modelo ajusta sus parámetros para minimizar el error en sus predicciones comparándolas con los resultados reales. Este proceso continúa hasta que el modelo se optimiza adecuadamente para realizar predicciones precisas. El aprendizaje supervisado es ampliamente utilizado en aplicaciones como la clasificación (donde las salidas son categorías o clases) y la regresión (donde las salidas son valores continuos).

Aprendizaje No Supervisado: A diferencia del aprendizaje supervisado, en el aprendizaje no supervisado, el algoritmo intenta descubrir patrones y estructuras inherentes en los datos sin ninguna guía explícita sobre qué resultados se deben predecir. Este enfoque se utiliza comúnmente para tareas de agrupación (clustering) y reducción de dimensionalidad. En la agrupación, el objetivo es dividir el conjunto de datos en grupos basados en similitudes entre las características de los datos, mientras que la reducción de dimensionalidad busca simplificar los datos conservando las características más relevantes. El aprendizaje no supervisado es especialmente útil para explorar los datos y obtener insights cuando no se conocen las categorías o resultados previamente.

Aprendizaje Semi-supervisado: El aprendizaje semi-supervisado es un enfoque de aprendizaje automático que combina aspectos tanto del aprendizaje supervisado como del no supervisado. En este enfoque, el algoritmo se entrena con un conjunto de datos que contiene tanto ejemplos etiquetados como no etiquetados. Aunque la mayoría de los datos no tienen etiquetas, la pequeña cantidad de datos etiquetados se utiliza para guiar el proceso de aprendizaje y ayudar al algoritmo a descubrir la estructura y las características subyacentes en los datos no etiquetados. Este método es particularmente útil cuando la obtención de etiquetas es costosa o laboriosa, permitiendo al modelo aprender y generalizar mejor a partir de una cantidad limitada de datos etiquetados. El aprendizaje semi-supervisado es comúnmente aplicado en situaciones donde los datos no etiquetados son abundantes, pero las etiquetas son escasas o difíciles de obtener.

Aprendizaje Auto-supervisado: A diferencia de otros tipos de aprendizaje, en el aprendizaje auto-supervisado no se requieren etiquetas proporcionadas externamente. En cambio, el modelo genera tareas de predicción basadas en partes de la entrada. Por ejemplo, puede aprender a predecir una parte de los datos faltantes a partir de otra parte de los mismos datos. Esta técnica es útil para extraer información útil de grandes cantidades de datos no etiquetados y es comúnmente aplicada en tareas como el procesamiento del lenguaje natural y el análisis de imágenes, donde se puede aprender una representación significativa de los datos sin necesidad de una anotación manual costosa y que consume tiempo.

Normalmente, esta estrategia utiliza una configuración Encoder-Decoder como el Autoencoder de la figura 1.3, en ella una imagen es usada a la entrada y la tarea del Autoencoder es producir a la salida una imagen igual (o lo más parecida posible) a la entrada. Un subproducto es que el bloque Decoder puede ser usado posteriormente para generar imágenes. Un proceso análogo, en una configuración Encoder-Decoder, es usada para entrenar los Grandes Modelos de Lenguaje (o LLM Large Language Model) que han permitido el desarrollo de aplicaciones como Chat GPT.

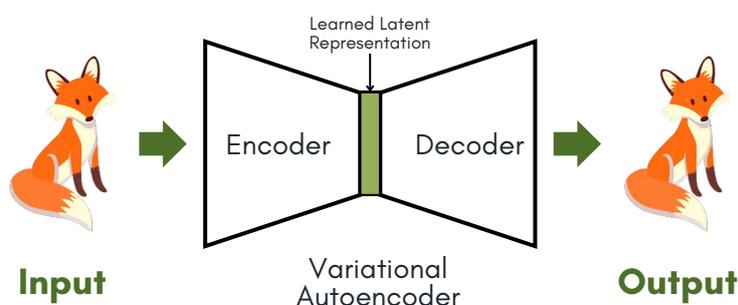


Figura 1.3: Autoencoder que utiliza aprendizaje auto-supervisado. Fuente: Creixell W., 2023

Aprendizaje por Refuerzo: En este tipo de aprendizaje, un agente aprende a tomar decisiones optimizando sus acciones en un entorno específico para maximizar una recompensa acumulativa. El agente experimenta con acciones y observa los resultados en términos de recompensas o penalizaciones. Este proceso le permite aprender qué acciones conducen a los mejores resultados a lo largo del tiempo. El aprendizaje por refuerzo es notablemente efectivo en situaciones donde las decisiones correctas o las políticas óptimas no son conocidas de antemano. Se utiliza ampliamente en diversas aplicaciones, como juegos, robótica, optimización de procesos industriales y navegación autónoma, donde el agente debe tomar decisiones secuenciales basadas en la retroalimentación del entorno.

1.2 Inteligencia Artificial en el sector Silvoagropecuario

La agroindustria es un ámbito crítico donde las acciones imprudentes o el monitoreo negligente pueden provocar muertes de animales, pérdidas de cosechas, pérdidas financieras e incluso desequilibrio económico nacional. En la ganadería, que implica la cría de animales para consumo humano, niveles inadecuados de ciertas variables, como la humedad y/o la temperatura en el ambiente de producción, pueden conducir, por ejemplo, al desarrollo de enfermedades e inflamación en las glándulas de los animales que pueden causar una reducción en producción o incluso pérdida total. [3]

Se estima que para 2050, la demanda mundial de alimentos aumentará en un 70% y la demanda de carne aumentará en más de un 50%. Esta creciente demanda ha contribuido al rápido crecimiento de la industria ganadera mundial. Este crecimiento también ha traído algunos problemas: la pérdida y degradación de los bosques a nivel mundial, los impactos negativos sobre el medio ambiente, el clima y la biodiversidad. Esto significa que, además de satisfacer la necesidad de producir más productos animales, el sector ganadero debe implementar programas de producción más eficientes y sostenibles. Por tanto, es necesario que la industria ganadera se desarrolle gradualmente en dirección a la intensificación y la sostenibilidad. [4]



Con la población en continuo crecimiento, la seguridad alimentaria es actualmente una de las principales preocupaciones del mundo. La superficie de tierra disponible para el cultivo agrícola y el pastoreo de animales se está reduciendo gradualmente debido al aumento de la industrialización, particularmente en las economías emergentes de África, Asia y América Latina. Esta situación viene en aumento debido al cambio climático, los bajos ingresos, la falta de conocimiento sobre herramientas y técnicas modernas, etc. Además, se espera que las emisiones globales de gases de efecto invernadero (GEI) aumenten en un 50% para 2050, junto con una expansión de la población urbana del 66%, una reducción de alrededor de 50 millones de hectáreas de tierras cultivables, una caída del 20% en la producción agroalimentaria, y un aumento del 59 al 98 % en el consumo de alimentos, todo lo cual intensificará el peligro relacionado con la seguridad alimentaria y la nutrición. [5]

Afortunadamente, el sector agrícola ha venido experimentando una transformación impulsada por nuevas tecnologías, lo que parece muy prometedor ya que permitirá a este sector primario pasar al siguiente nivel de productividad y rentabilidad. Debido a limitaciones impuestas por el clima, los suelos, la hidrología, las plantas, los animales, los bosques y la salud humana, la agricultura tradicional muchas veces no logra asegurar los alimentos. La agricultura moderna ha permitido que más personas coman mejor y más alimentos en todo el mundo. Una de esas prácticas agrícolas es la agricultura de precisión, que implica aplicar insumos sólo cuando y donde se necesitan, y ha surgido como la tercera ola de la revolución agrícola contemporánea (las dos primeras olas fueron la mecanización y la revolución verde con su modificación genética). Para garantizar la sostenibilidad de los productos agrícolas, también se utilizan cada vez más nuevas tecnologías teniendo en cuenta el medio ambiente. [6]

La Agricultura 4.0, también conocida como agricultura basada en datos o agricultura inteligente o digital, utiliza la telemática, la gestión de datos y la agricultura de precisión para aumentar la calidad de los cultivos. El Consejo Nacional de Investigación (1997) define la agricultura de precisión como la aplicación de tecnologías de información modernas para proporcionar, procesar y analizar datos de múltiples fuentes, de alta resolución espacial y temporal para la toma de decisiones y operaciones en el manejo de la producción de cultivos. La agricultura de precisión se centra en la aplicación de insumos (por ejemplo, fertilizantes, pesticidas) cuando sea necesario en cantidades específicas. Esto optimiza los recursos y hace que las plantas reciban lo que realmente necesitan. Tradicionalmente, los agricultores recorren los campos para comprobar las condiciones de los cultivos y tomar decisiones en base a la experiencia adquirida. Este método convencional ya no es viable porque el tamaño de los campos ha crecido enormemente y los métodos tradicionales exigen más recursos de trabajo.

A diferencia de la Agricultura 4.0, la Agricultura 5.0 además de la agricultura de precisión utiliza equipos no tripulados y autónomos. Es decir, la robótica y la Inteligencia Artificial empiezan a jugar un papel importante en este campo. Tecnológicamente, la visión por computadora, el aprendizaje automático y los vehículos aéreos no tripulados, o comúnmente conocidos como drones, permiten construir el sistema de Agricultura 5.0. [7]



Sin embargo, todas las soluciones agrícolas inteligentes dependen de la conectividad. Hay pocas aplicaciones en las que la conexión sea más crítica que en la agricultura contemporánea.

Especialmente teniendo en cuenta que la agricultura suele realizarse en lugares distantes y de difícil acceso, muy fuera de las zonas urbanizadas con Wi-Fi estable. Las zonas rurales tienen poco o ningún acceso a conexiones de redes públicas. La agricultura requiere datos importantes y, estos datos deben poder transmitirse. [8]

Pero el sector silvoagropecuario no es sólo alimentos, considera también la silvicultura o prácticas forestales, y la floricultura, que es la horticultura orientada al cultivo de flores y plantas ornamentales.

Los esfuerzos forestales se componen de una gran cantidad de tareas para mantener los bosques sanos y alcanzar todo su potencial, realizadas principalmente de forma manual, lo que hace que las operaciones forestales sean bastante laboriosas, costosas y peligrosas. La silvicultura se puede clasificar en términos generales en monitoreo e inventario forestal, monitoreo de la vida silvestre, búsqueda/rescate y monitoreo de incendios forestales. Para el inventario forestal hay que recopilar y armonizar datos de los bosques, por ejemplo, la altura y diámetro del árbol, las especies de árboles y el número de árboles de cada especie, etc. La integración de la Inteligencia Artificial y los drones tiene un inmenso potencial para mejorar las prácticas forestales y contribuir a la gestión sostenible de la tierra. [9]

Las flores ornamentales tienen importantes funciones sociales, estéticas y culturales en la sociedad, y la floricultura es una actividad económicamente importante. Sólo los Países Bajos son responsables de más del 50% de la producción mundial de flores y plantas ornamentales, con un valor de exportación de 12 mil millones por año. Un registro o catálogo de variedades de flores con un conjunto de rasgos que definen de manera única una variedad es una herramienta importante en el ecosistema de la floricultura. Estos rasgos incluyen el color o combinación de colores, el nivel de llenado/apertura del centro de la flor, la distribución en la planta (individual o en racimos) y las dimensiones de la superficie, floretes o pétalos. Además de este aspecto de la distinción, se utilizan descripciones similares en las pruebas de uniformidad y estabilidad (que juntas forman las pruebas de Distinción, Uniformidad y Estabilidad). Actualmente, este proceso lo realizan manualmente expertos que inspeccionan muestras de flores de una variedad potencialmente nueva y anotan los valores de los rasgos respectivos. [10]

Con la creciente disponibilidad de datos y los avances continuos en los algoritmos de aprendizaje automático, la Inteligencia Artificial está preparada para impulsar la innovación y la eficiencia en la floricultura, transformando la forma en que los consumidores cultivan, comercializan y aprecian las flores. [11]



2. Panorama Científico

El análisis de los avances científicos relacionados a los conceptos de inteligencia artificial en el sector silvoagropecuario, se centró en la identificación, compilación y análisis de las publicaciones científicas de los últimos cinco años, contenidas en la base de datos Scopus. Esta base de datos es la mayor base de datos de resúmenes hasta ahora vista en el mundo, con 20.500 publicaciones (85% de las cuales están indizadas con vocabulario controlado) procedentes de más de 5.000 editoriales internacionales. Representa aproximadamente un 80% de las publicaciones internacionales revisadas por especialistas.

2.1 Evolución de la producción científica

De acuerdo al número de publicaciones por año, en la Figura 2.1 se observa una década de publicaciones donde la investigación en este tema comienza el año 2016 y luego de cuatro años se produce un auge en el interés con un comportamiento prácticamente exponencial.

La curva de la producción científica refleja un enorme esfuerzo en cuanto al desarrollo de esta nueva disciplina, nuevos métodos y arquitecturas, además de tratar de resolver los problemas que aún tiene la IA, como por ejemplo los modelos que aún no son explicables, es decir lo que funciona bien pero no se puede explicar por qué funciona bien, y así evitar comportamientos negativos o resultados no deseados. Además, cuando hay un desarrollo fuerte en la disciplina de la IA y estos desarrollos se trasladan a las aplicaciones, por ejemplo en este caso a la agricultura, la producción científica es todavía mayor, generando un efecto multiplicador.

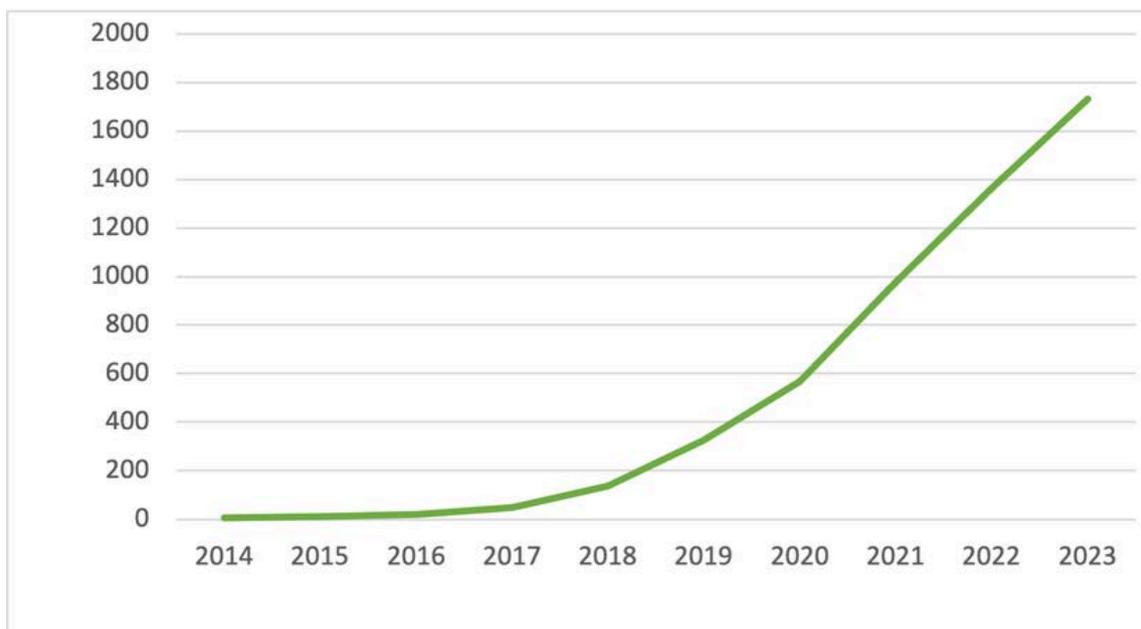


Figura 2.1: Producción científica para el período 2014–2023
Fuente: IALE Tecnología, elaboración propia



En lo específico, la base de datos antes mencionada fue consultada para el período 2019 al 2023, identificándose un total de 4.900 publicaciones. A continuación se presentan los principales resultados obtenidos del análisis de dicho volumen de información.

En cuanto a la evolución de las publicaciones científicas se confirma una distribución absolutamente creciente en el tiempo respecto a la cantidad de publicaciones en este tema. (Figura 2.2)

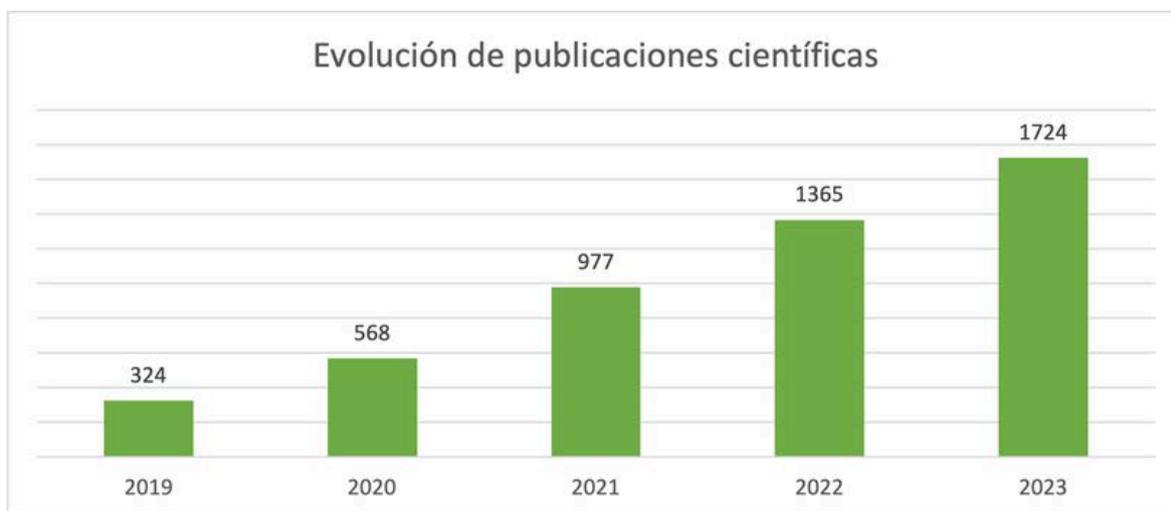


Figura 2.2: Producción científica para el período 2019-2023
Fuente: IALE Tecnología, elaboración propia

2.2 Identificación de actores líderes

2.2.1 Principales países

El desarrollo de producción científica mundial desde el año 2019 a la fecha, ha venido de la mano de 77 países, siendo India y China los líderes indiscutidos en esta materia, con 1.324 y 1.297 publicaciones respectivamente, equivalente al 53% de las publicaciones identificadas en el área de interés. Le sigue Estados Unidos con 448 publicaciones, y muy por debajo los países de Arabia Saudita, Corea del Sur, Reino Unido, Japón, Italia, Alemania, entre otros (ver Figura 2.3). Destaca la presencia de Brasil entre los 16 países líderes, con más de 90 publicaciones.



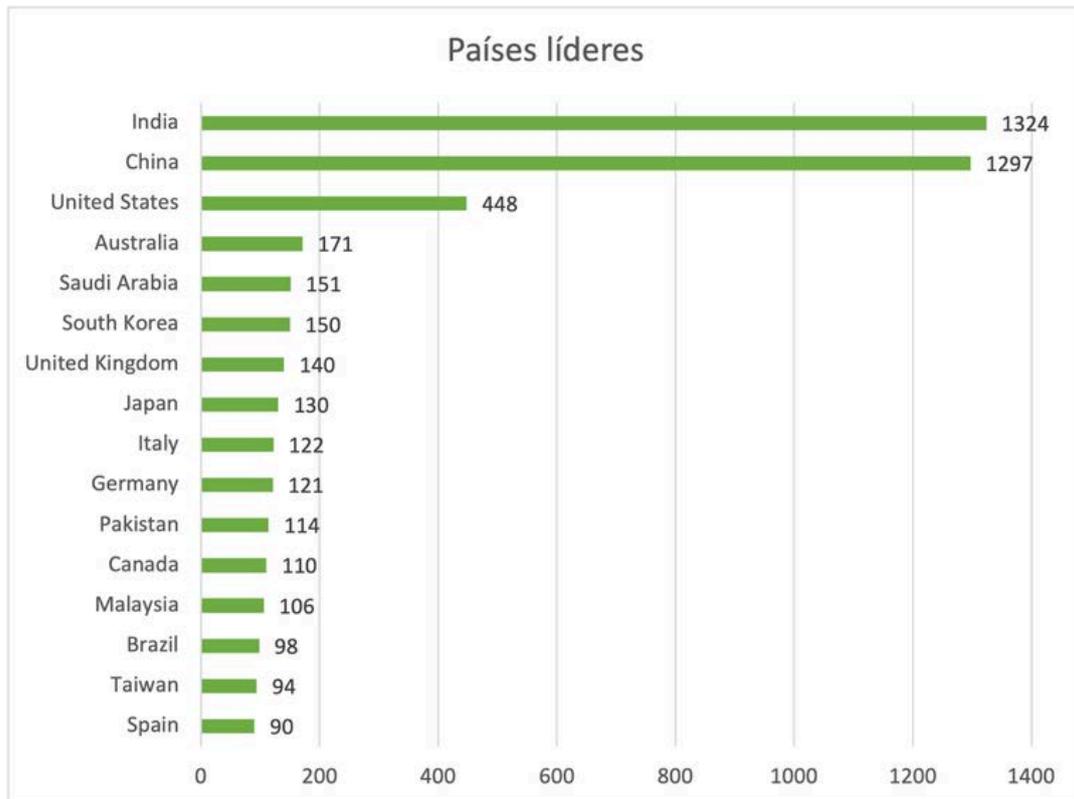


Figura 2.3: Países líderes en producción científica para el período 2019-2023
Fuente: IALE Tecnología, elaboración propia

En lo que respecta a países de Centro y Sudamérica, el líder es Brasil con 98 publicaciones, seguido muy por debajo de México, Colombia, Perú, Ecuador, Chile, Argentina, Costa Rica, Uruguay, Panamá y Honduras (ver Figura 2.4).

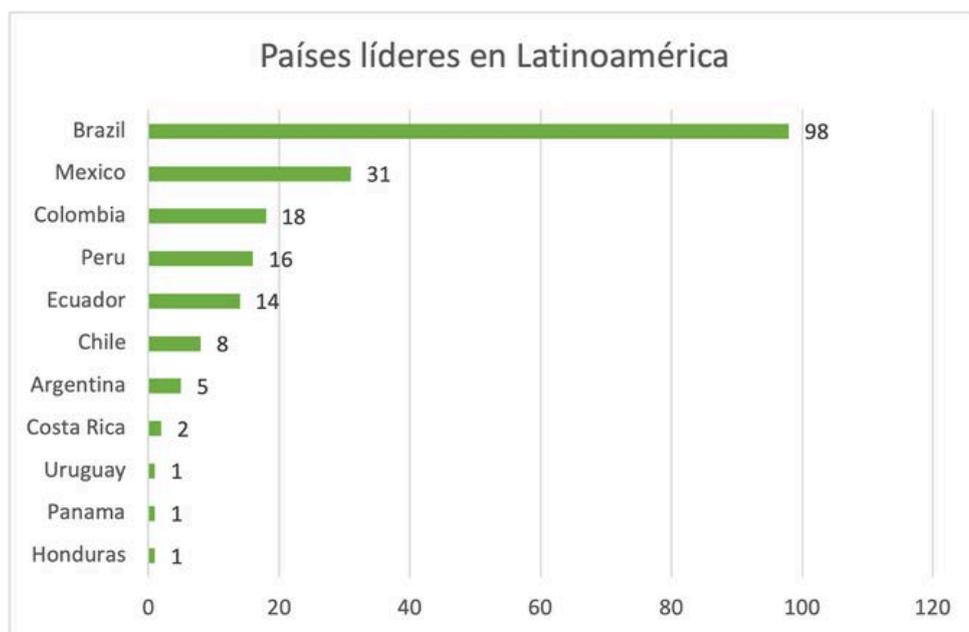
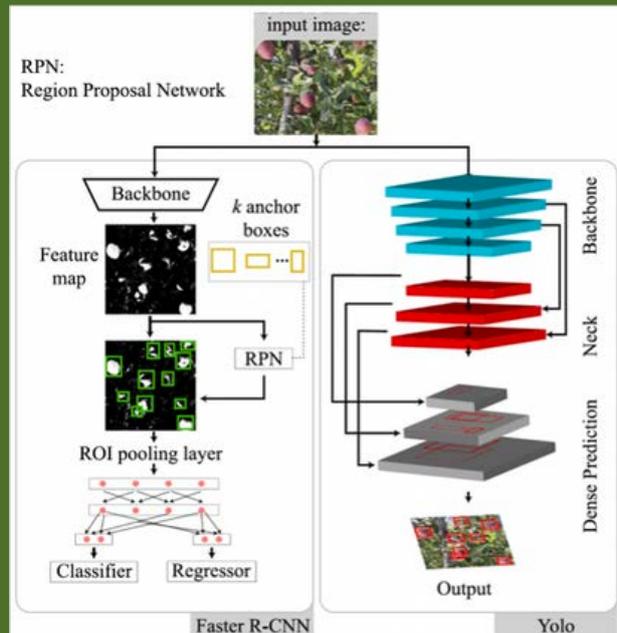


Figura 2.4: Países líderes de Latinoamérica en producción científica período 2019-2023
Fuente: IALE Tecnología, elaboración propia

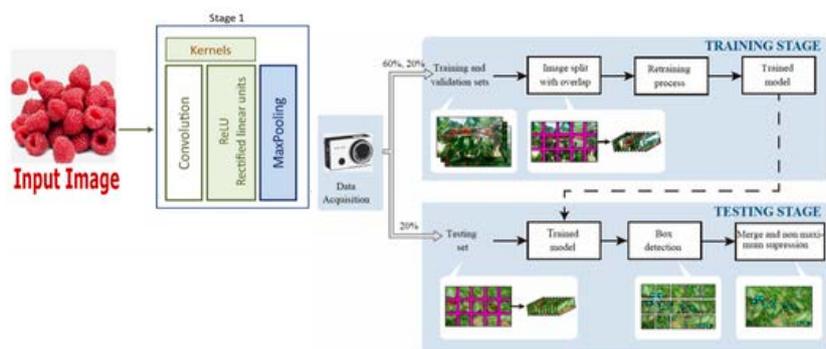
Para el caso particular de Chile, se identificaron ocho trabajos vinculados a instituciones nacionales, de los cuales cinco de ellos se han desarrollado en colaboración con instituciones de Estados Unidos, México, Costa Rica, Brasil y España. La más reciente publicación corresponde al trabajo del 2023 titulado **Apple orchard production estimation using deep learning strategies: A comparison of tracking-by-detection algorithms**¹, publicación conjunta entre la Universidad Técnica Federico Santa María, la Universidad de Los Andes y la Universidad de California, la cual presenta una comparación exhaustiva de cinco algoritmos de Tracking-by-detection aplicados al recuento de manzanas en los árboles.

Los algoritmos se evaluaron en dos bases de datos construidas para la investigación en formato MOT (Multiple Object Tracking), demostrando que el enfoque más robusto es el Multiple Hypothesis Tracking, seguido por el Deep Simple Online Realtime (DeepSORT), con una precisión MOT de 97,00% y 93,00%, respectivamente.



A **Systematic Mapping of Smart Farming and Image Recognition in Agriculture** (2021)² de la Universidad de la Frontera, es un estudio comparativo de diferentes herramientas de deep learning para identificar enfermedades de las plantas, específicamente compara modelos de clasificación de imágenes y aplicaciones de visión artificial para la agricultura.

La publicación de la Universidad Católica del Maule **A review of convolutional neural network applied to fruit image processing** (2020)³, presenta una revisión del uso de las CNN aplicadas a diferentes tareas de procesamiento automático de imágenes de frutas: clasificación, control de calidad y detección.



Además, presenta los fundamentos, herramientas y dos ejemplos del uso de CNN para la clasificación y control de calidad de frutas. La Universidad Federico Santa María aporta con la publicación **Detection and characterization of cherries: A deep learning usability case study in Chile** (2020)⁴, que muestra el desarrollo de un método deep learning y un sistema de visión artificial portátil para mejorar las estimaciones de cosecha de cerezas. Pudo detectar cerezas con hasta un 85% de precisión y estimar la producción con hasta un 25% de error. Además, logró clasificar las cerezas en cuatro tamaños, para una mejor caracterización de la producción de exportación.

¹ [Enlace](#)
² [Enlace](#)
³ [Enlace](#)
⁴ [Enlace](#)

2.2.2 Principales instituciones

Respecto a las instituciones líderes, con treinta o más publicaciones, en el top se encuentra el Ministerio de Agricultura de China, luego destacan principalmente instituciones académicas chinas e indias. Le siguen universidades e institutos de Estados Unidos, Australia, Japón y Europa (ver Figura 2.5).



Figura 2.5: Instituciones líderes en producción científica para el período 2019-2023
Fuente: IALE Tecnología, elaboración propia

Los centros de investigación más destacados por su cantidad de publicaciones son los descritos a continuación.

El Consejo Indio de Investigación Agrícola (ICAR)⁵ es una organización autónoma dependiente del Ministerio de Agricultura de la India, con sede en Nueva Delhi. Es el organismo encargado de coordinar, orientar y gestionar la investigación y educación en agricultura, incluidas la horticultura, pesca y ciencias animales, en todo el país. Con 113 institutos y 74 universidades agrícolas en la India, es uno de los sistemas agrícolas nacionales más grandes del mundo.

⁵ [Enlace](#)



Empresa Brasileira de Pesquisa Agropecuária (Embrapa)⁶, es una institución enfocada a la innovación para generar conocimiento y tecnologías para la agricultura brasileña. Es una empresa pública, vinculada al Ministerio de Agricultura y Ganadería, creada en 1973 para desarrollar las bases tecnológicas de un modelo agrícola y ganadero genuinamente tropical. Su desafío es garantizar a Brasil la seguridad alimentaria y una posición destacada en el mercado internacional de alimentos, fibras y energía.

Consiglio Nazionale delle Ricerche (CNR)⁷, es la institución pública de investigación más grande de Italia, dependiente del Ministerio de Investigación. Su objetivo es realizar investigaciones en sus propios institutos, promover la innovación y la competitividad del sistema industrial nacional, y proporcionar tecnologías y soluciones al sector público y privado.

Organización de Investigación Científica e Industrial del Commonwealth (CSIRO)⁸ es una agencia independiente del gobierno federal australiano responsable de la investigación científica, y una de las diez organizaciones de ciencia más importantes del mundo. Su función principal es mejorar el desempeño económico y social de la industria en beneficio de la comunidad. Cuenta con 60 centros en Australia y el mundo, incluido uno en Chile⁹.

A nivel nacional se detectan seis universidades de nuestro país (ver Figura 2.6).



Figura 2.6: Instituciones nacionales líderes en producción científica período 2019-2023

Fuente: IALE Tecnología, elaboración propia

⁶ [Enlace](#)

⁷ [Enlace](#)

⁸ [Enlace](#)

⁹ [Enlace](#)



2.2.3 Principales autores

Los investigadores líderes, con diez o más publicaciones (ver Figura 2.7), son en su gran mayoría chinos o indios.



Figura 2.7: Investigadores líderes en producción científica período 2019-2023
Fuente: IALE Tecnología, elaboración propia

El investigador líder es **Dr. Vinay Kukreja¹⁰**, con 32 publicaciones, PhD en Computer Science, profesor e investigador de la **Universidad de Chitkara**, universidad privada ubicada al norte de India. Es especialista en procesamiento de imágenes y Computer Vision. En el sector agrícola, sus publicaciones destacan en el área de enfermedades de plantas (detección de enfermedades de plantas con deep learning).

Le sigue en liderazgo **Yongliang Qiao¹¹**, con 25 publicaciones, PhD en Computer Science, un investigador de la **Universidad de Adelaide**, Australia. Especialista en deep learning, sus líneas de investigación son robótica agrícola y ganadería de precisión.

En Estados Unidos destaca **Arnold Schumann¹² con 11 publicaciones, académico de la Universidad de Florida** (Institute of Food and Agricultural Sciences). Sus publicaciones se centran en deep learning y agricultura.

El investigador portugués **Pedro Dinis Gaspar¹³** destaca en Europa con 10 publicaciones, es PhD en ingeniería mecánica, de la **Universidad de Beira Interior**. Sus áreas de investigación son Automatización, Robótica, Sistemas Embebidos y Sistemas de Control.

¹⁰ [Enlace](#)

¹¹ [Enlace](#)

¹² [Enlace](#)

¹³ [Enlace](#)

En Chile, sin pretender ser exhaustivos, los investigadores que aparecen dentro de los resultados de acuerdo a los criterios de búsquedas utilizados, se presentan en la siguiente tabla.

Tablanº1: Investigadores nacionales

INVESTIGADORES NACIONALES		
INSTITUCIÓN	DEPARTAMENTO	INVESTIGADOR
Universidad Católica del Maule	Departamento de Ciencias Agrícolas	Fredes C.
	Departamento de Economía y Administración	Valenzuela A.
	Centro de Investigación en Estudios Avanzados del Maule, Vicerrectoría de Investigación y Postgrado	Mesquita-Neto J.N. jmesquita@ucm.cl
	Laboratorio de Investigación Tecnológica en Reconocimiento de Patrones (LITRP)	Naranjo-Torres J. jnaranjo@ucm.cl Mora M. Hernández-García R. Barrientos R.J.
Universidad de Concepción	Facultad de Ciencias Forestales	Valverde-Otárola J.C.
	Facultad de Ingeniería Agrícola	Lillo-Saavedra M.

Universidad de Concepción	Facultad de Ciencias Forestales	Valverde-Otárola J.C.
	Facultad de Ingeniería Agrícola	Lillo-Saavedra M.
Universidad Técnica Federico Santa María	Departamento de Electrónica	Viscaino M.
		Auat Cheein F. fernando.auat@usm.cl
		Villacrés J.F.
Universidad de la Frontera	Departamento de Computación	Rios B.G.
	Departamento de Ingeniería Eléctrica	Saldias M.C.
Universidad de los Andes	Departamento de Ingeniería	Delpiano J.
Universidad Adventista de Chile	Facultad de Ingeniería y Negocios	Quiroz I.A.

2.3 Líneas de investigación

Para efectos de análisis, se dividió el corpus de información en las cuatro áreas del sector silvoagropecuario: agricultura, ganadería, silvicultura y floricultura. En cada una de estas cuatro áreas se presenta una gráfica con los principales descriptores o palabras claves asociados a cada una de las publicaciones científicas, donde los términos de mayor tamaño son los que tienen mayor frecuencia de aparición, es decir, son los más utilizados por los investigadores que publican, debido al elevado interés que han generado en la comunidad científica a lo largo del período de estudio.

2.3.1 AGRICULTURA

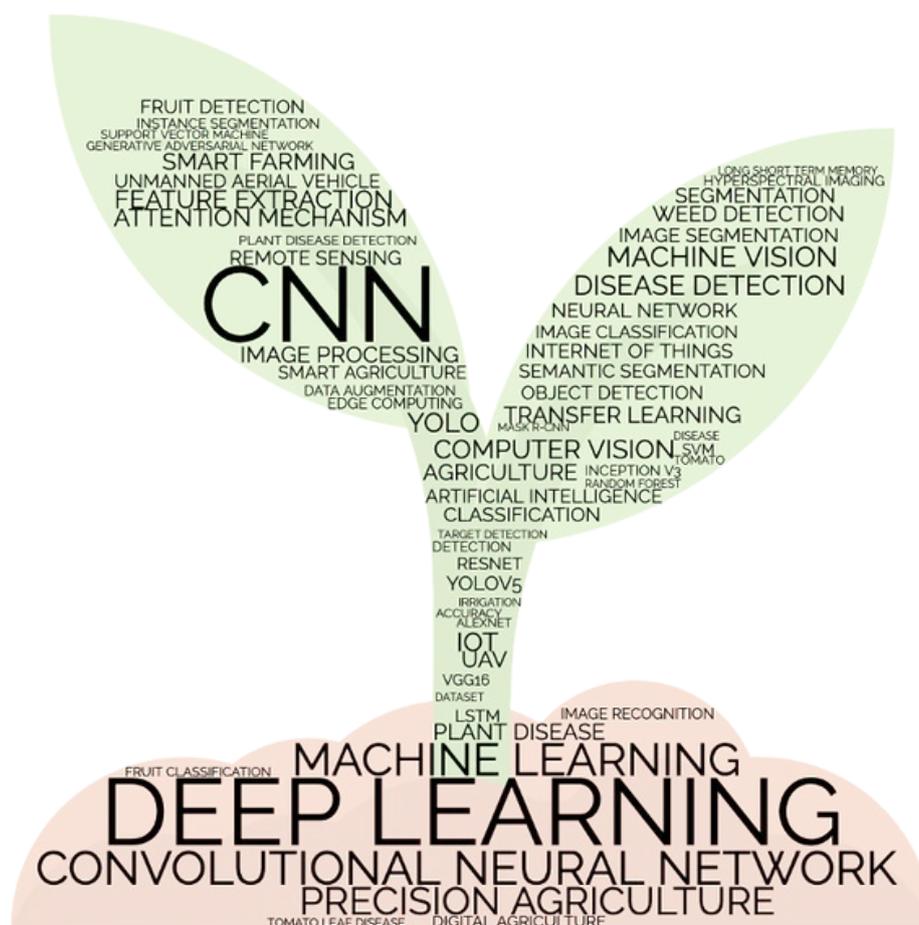


Figura 2.8: Descriptores con mayor frecuencia de aparición en agricultura
Fuente: IALE Tecnología, elaboración propia

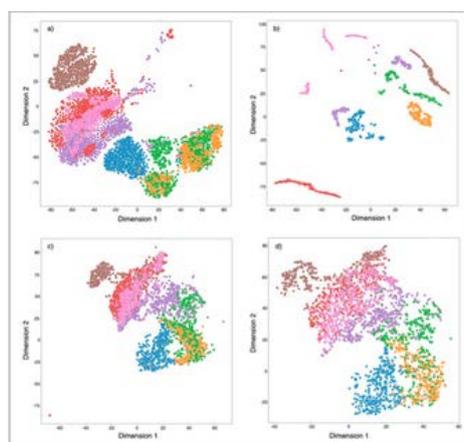
Como se aprecia en la Figura 2.8, los conceptos de Inteligencia Artificial (IA) que predominan son Deep learning, convolucional neural network (CNN), y machine learning, conceptos intrínsecos de IA. Como conceptos asociados a visión aparece Machine vision y Computer vision, y junto a ellos aparecen tratamientos de imágenes como Image recognition, image segmentation, image classification, image processing, object detection, hyperspectral imaging. Como tecnologías propiamente tal aparecen IoT, UAV, remote sensing, entre otros. Finalmente, como algoritmos específicos de deep learning aparece YOLO (You Only Look Once) en todas sus versiones, sistema de código abierto para la detección de objetos en tiempo real.



Las aplicaciones de IA detectadas en agricultura, a grandes rasgos son: **1) enfermedades y plagas de plantas (detección, identificación, clasificación, predicción y monitoreo, deficiencia de nutrientes); 2) Frutas (detección, reconocimiento, clasificación, ordenamiento); 3) Robótica agrícola y picking.** A continuación algunas publicaciones destacadas en estos campos.

Las plagas de insectos son un problema en la horticultura por lo que su detección temprana es importante para su control. Las trampas adhesivas son una forma económica de obtener muestras de insectos, pero identificarlas manualmente es una tarea que requiere mucho tiempo. Por lo tanto, es muy deseable construir modelos computacionales para identificar especies de insectos en imágenes de trampas adhesivas. Sin embargo, esta es una tarea desafiante debido a la dificultad de obtener conjuntos considerables de imágenes de entrenamiento.

La publicación peruana **Investigating Generative Neural-Network Models for Building Pest Insect Detectors in Sticky Trap Images for the Peruvian Horticulture (2022)**¹⁴ de tres modelos generativos de redes neuronales para sintetizar imágenes de insectos para aumentar el conjunto de entrenamiento y así facilitar la inducción de modelos detectores de insectos. Experimentos con imágenes de siete especies de insectos peligrosos de la horticultura peruana demostraron que los modelos WGAN y VAE son capaces de aprender a generar imágenes de dichas especies.



También se descubrió que las imágenes sintetizadas pueden ayudar a inducir detectores YOLOv5m con ganancias significativas en el rendimiento de detección en comparación con no utilizar datos sintetizados.

La presencia de tizón tardío en cultivos de papa afecta directamente el crecimiento de las plantas y el desarrollo de los tubérculos; por lo tanto, es importante la detección temprana de la enfermedad. Actualmente, la aplicación de redes neuronales convolucionales es una oportunidad orientada a la identificación de patrones en agricultura de precisión, incluyendo el estudio del tizón tardío en cultivos de papa. En la publicación colombiana **Application of convolutional neural networks for detection of the late blight *Phytophthora infestans* in potato *Solanum tuberosum*; [Aplicación de redes neuronales convolucionales para la detección del tizón tardío *Phytophthora infestans* en papa *Solanum tuberosum*]** (2021)¹⁵ se describe un modelo de deep learning capaz de reconocer el tizón tardío en cultivos de papa mediante clasificación de imágenes foliares.

Los resultados experimentales obtenidos con el conjunto de datos seleccionado mostraron que el modelo propuesto logra una precisión del 90 % y una puntuación F1 del 91 %. Por lo tanto, el modelo propuesto es una herramienta útil para los agricultores en la identificación del tizón tardío y escalable a plataformas móviles debido a la cantidad de parámetros que lo componen.



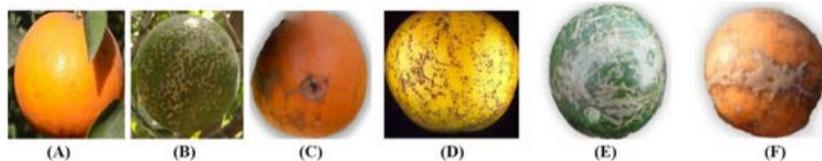
¹⁴ [Enlace](#)

¹⁵ [Enlace](#)



El tomate es una de las hortalizas más cultivadas en el mundo y sus enfermedades pueden afectar significativamente su rendimiento y calidad. La detección temprana y precisa de ellas es crucial para disminuir las pérdidas y mejorar el manejo de sus cultivos. El deep learning y CNN disponen de múltiples diseños de modelos para la identificación automatizada de enfermedades de las plantas en vez de la detección tradicional basada en inspección visual. Cuando se utilizan métodos deep learning, el conjunto de datos cumple una de las funciones más cruciales en la predicción de enfermedades. PlantVillage es el dataset público más utilizado para la detección de enfermedades del tomate, pero se creó en un entorno controlado o de laboratorio, y los modelos entrenados en él no funcionan bien en imágenes del mundo real. Algunos conjuntos de datos naturales o del mundo real están disponibles, pero son privados y no están disponibles públicamente. La publicación india **"Tomato-Village": a dataset for end-to-end tomato disease detection in a real-world environment (2023)**¹⁶, presenta el primer conjunto de datos público (Tomato-Village) para la detección de enfermedades del tomate, especialmente aquellas asociadas a minadores de hojas, virus del marchitamiento manchado y enfermedades por deficiencia nutricional. Sobre este dataset se pueden aplicar diversas arquitecturas/modelos de CNN para predecir tempranamente enfermedades en cultivos de tomate.

Los cítricos son delicados y susceptibles a muchas enfermedades e infecciones. Muchos investigadores han sugerido modelos de detección y clasificación de enfermedades de la fruta basados en deep learning. La publicación india **PFDI: a precise fruit disease identification model based on context data fusion with faster-CNN in edge computing environment (2023)**¹⁷, presenta un modelo preciso de identificación de enfermedades de cítricos basado en un ambiente edge computing con Faster-CNN. Este modelo emplea imágenes de dos patrones: infrarrojo cercano (NIFR) y RGB. La precisión obtenida del modelo propuesto para la enfermedad del cancro es del 97%, la sarna del 95%, la melanosis del 99%, el enverdecimiento del 97%, la mancha negra del 97% y la no enfermedad del 97%.



La detección y el control de plagas pueden garantizar eficazmente la calidad y el rendimiento de los cultivos. Los métodos de detección de objetos existentes basados en CNN proporcionan estrategias viables para la detección de plagas; sin embargo, su baja precisión y velocidad han restringido su implementación y aplicación en escenarios agrícolas reales. En la publicación china **Real-time and effective detection of agricultural pest using an improved YOLOv5 network (2023)**¹⁸, se propone un modelo YOLOv5 mejorado para la detección eficaz y en tiempo real de plagas agrícolas. Para asignar pesos dinámicos a diferentes campos receptivos y resaltar las contribuciones desiguales de éstos a la información global, se propone la fusión de características con campos atencionales multireceptivos. Los resultados experimentales en un conjunto de datos públicos de plagas a gran escala (Pest24) demuestran que este método supera al YOLOv5 original y otros modelos de última generación. El mAP mejora del 71,5 al 74,1%, la velocidad de detección mejora de 79,4 FPS a 104,2 FPS, los FLOP disminuyen un 42% y el tamaño del modelo se comprime un 39%. Así, la detección y el control de plagas pueden garantizar eficazmente la calidad y el rendimiento de los cultivos.

¹⁶ [Enlace](#)

¹⁷ [Enlace](#)

¹⁸ [Enlace](#)

Han pasado más de 30 años desde que los franceses fueron pioneros en la investigación del robot cosechador de manzanas y, con los esfuerzos conjuntos de académicos de todo el mundo, se han desarrollado varios prototipos. Sin embargo, el prototipo de robot actual todavía se encuentra en la etapa de investigación experimental debido a su baja eficiencia de recolección. Con la ayuda de las tecnologías de información, la investigación ha



marcado el comienzo de un desarrollo histórico y está llena de oportunidades y desafíos para los investigadores de robótica recolectora de manzanas. La publicación china **Current status and future development of the key technologies for apple picking robots (2023)**¹⁹, presenta una visión general de la historia y el estado actual de los robots recolectores de manzanas comerciales. El desarrollo de estos robots capaces de detectar manzanas en entornos complejos y recogerlas sin dañar la fruta o los árboles es de gran importancia para las operaciones de picking en los campos. El rendimiento de los robots recolectores se puede evaluar mediante la velocidad de recolección, el éxito de la recolección y las tasas de daño de la fruta. Estos parámetros dependen de tres tecnologías clave: reconocimiento de objetos, localización y separación de frutos. Este estudio proporciona una referencia sólida para el estado actual, las tendencias de desarrollo futuras y la innovación de equipos de los robots recolectores de manzanas, junto con las tecnologías asociadas.

La alfalfa es fundamental para la seguridad alimentaria mundial, y los dataset disponibles son muchos a nivel nacional de EE. UU. pero escasos a nivel local, lo que limita el rendimiento de los modelos de aprendizaje automático (ML) para predecir los rendimientos de los campos. Pues entrenar modelos de ML con datos solo locales da como resultado una precisión de estimación muy baja cuando los conjuntos de datos son muy pequeños. La publicación norteamericana **Data Synthesis for Alfalfa Biomass Yield Estimation (2022)**²⁰, propone un proceso novedoso que entrena modelos de machine learning (ML) para predecir los rendimientos de alfalfa utilizando datos sintetizados a partir de datos no locales. Además, propone una aplicación de software llamada Predict Your CropS diseñada para ayudar a los agricultores e investigadores a estimar y predecir el rendimiento de los cultivos basándose en modelos previamente entrenados.

¹⁹ [Enlace](#)

²⁰ [Enlace](#)

La deficiencia de nutrientes durante el crecimiento de muchas plantas es una causa importante del menor rendimiento. Se puede mejorar si los niveles de nutrientes se controlan periódicamente y se mantienen mediante una fertilización y un control de plagas adecuados. Para realizar esta tarea, se ha desarrollado una amplia variedad de modelos de sistemas de procesamiento de imágenes, cuyo objetivo es analizar imágenes de plantas para buscar patrones visualmente aparentes de deficiencia de nutrientes. Pero estos sistemas son capaces de identificar deficiencias de nutrientes después de que la planta ha sido afectada por ellas. Por otro lado, se han desarrollado sistemas intrusivos que realizan análisis químicos de muestras de hojas para estimar estas deficiencias. La realización de dichos análisis químicos limita sus capacidades de prueba porque se toman muestras de hojas aleatorias para su evaluación, lo que limita su precisión. Para eliminar estos inconvenientes, la publicación india **Nutrient Defect Detection In Plant Leaf Imaging Analysis Using Incremental Learning Approach With Multifrequency Visible Light Approach (2023)**²¹, propone un marco de análisis de luz visible multifrecuencia no intrusiva para identificar deficiencias de nutrientes en una amplia variedad de plantas. El modelo propuesto fue evaluado para determinar el déficit de potasio, nitrógeno, cobre, zinc y fósforo en hojas de naranja, algodón, manzana, plátano, mango, litchi, henna, grosella y okra. Se observó que el enfoque propuesto tiene una precisión un 8% mayor que los modelos tradicionales y muestra una mejor precisión, recuperación y rendimiento de medición.

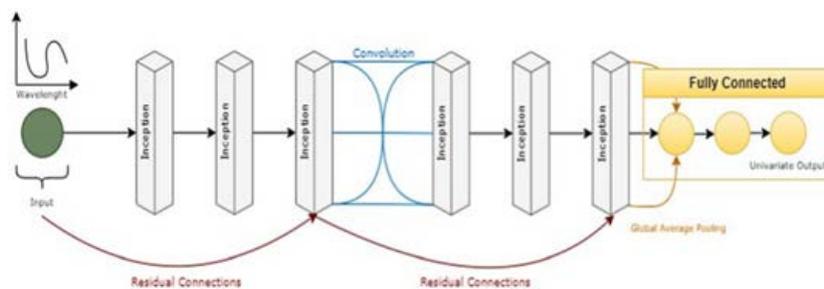
Otra publicación india, **Agroecology: Intelligent Implementation of Digital Farming Using machine Learning & Deep Learning (2023)**²², presenta un sistema inteligente llamado Agricultura Digital, que pretende ayudar a los agricultores a tomar una decisión informada sobre qué variedad cultivar, el fertilizante necesario para mejorar la productividad del suelo y el suministro de agua necesario según el suelo. No sólo el tipo de suelo y el tipo de cultivo juegan un papel importante en el rendimiento de los cultivos, sino que las plagas y malezas presentes en los campos agrícolas también causan grandes pérdidas a los agricultores, por lo que el modelo propuesto también detecta las plagas y malezas presentes en el campo y también recomienda pesticidas. El trabajo utiliza Convolution Neural Network (CNN) para clasificación de suelos, recomendación de cultivos y recomendación de fertilizantes, para la detección de plagas y recomendación de pesticidas utiliza K Nearest Neighbor (KNN), para la detección de malezas utiliza Support Vector Machine (SVM). CNN muestra una precisión del 91%, SVM muestra una precisión del 71% y KNN muestra una precisión del 83%.

En el estudio portugués **Boosting the performance of SOTA convolution-based networks with dimensionality reduction: An application on hyperspectral images of wine grape berries (2023)**²³, se aplicaron dos CNN (InceptionTime y OmniScale 1D- CNN) a imágenes hiperespectrales de uva de vino para estimar su madurez y contenido de azúcar. Ambos modelos fueron sometidos a diferentes pruebas con diversas cosechas y variedades de uva, mostrando una buena capacidad de generalización con resultados muy competitivos entre diferentes variedades y cosechas.

²¹ [Enlace](#)

²² [Enlace](#)

²³ [Enlace](#)



La industria agrícola se está transformando gracias a las recientes innovaciones en visión por computadora y deep learning. Sin embargo, la falta de conjuntos de datos específicos recopilados en entornos agrícolas naturales es, posiblemente, el principal obstáculo para los nuevos descubrimientos y la evaluación comparativa. La publicación uruguaya **MAGro dataset: A dataset for simultaneous localization and mapping in agricultural environments (2023)**²⁴ proporciona el conjunto de datos Magro Dataset V1.0, y un marco para ampliar su recopilación, el cual está disponible abiertamente. Consta de nueve bolsas ROS (y los datos sin procesar correspondientes) con datos recopilados en cultivos de manzanas y peras. Los datos se recopilaron repitiendo una trayectoria fija en diferentes días bajo diferentes condiciones climáticas y de iluminación.

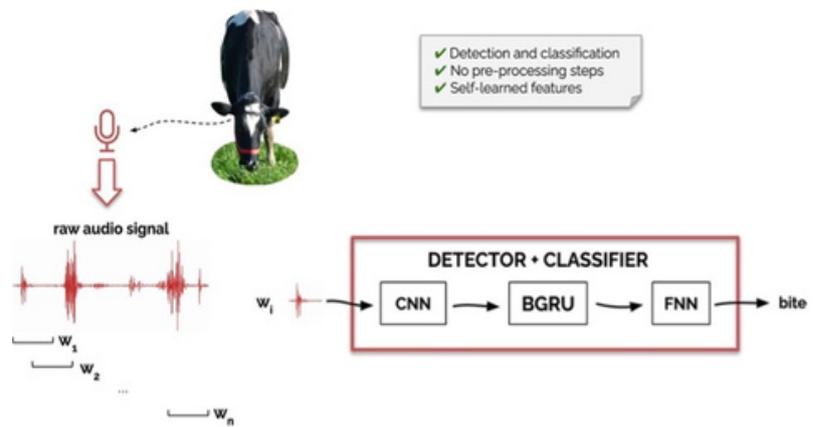
En la publicación norteamericana de uno de los investigadores líderes **Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks (2023)**²⁵, se analizó el desarrollo de seis modelos de redes neuronales de deep learning para detectar el estado de madurez en arándanos silvestres, junto con el desarrollo de modelos para la estimación del rendimiento. Las seis redes utilizadas fueron YOLOv3, YOLOv3-SPP, YOLOv3-Tiny, YOLOv4, YOLOv4-Small y YOLOv4-Tiny.



²⁴ [Enlace](#)

²⁵ [Enlace](#)

En el sector ganadero, un factor vital es la condición corporal del ganado, considerado un indicador nutricional ya que el nivel de grasa corporal subcutánea que se encuentra en ciertos puntos anatómicos determina los niveles de delgadez o gordura del animal.



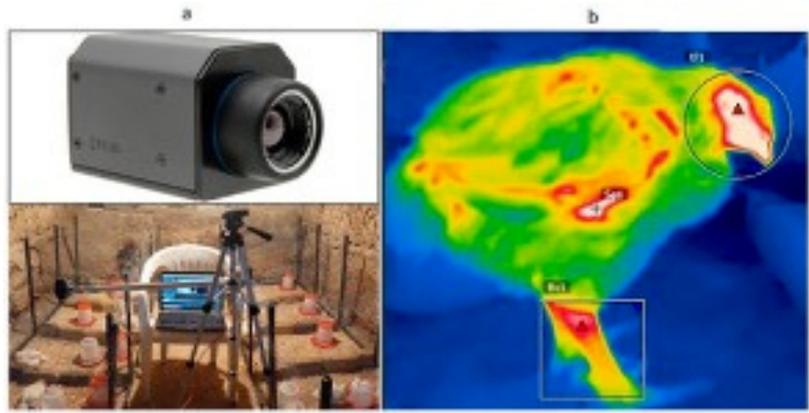
Por tanto, es una pista para definir las deficiencias nutricionales, un problema común en la industria ganadera. Proporcionar una evaluación oportuna de la condición corporal del ganado puede prevenir problemas nutricionales que mejoran la salud, los procesos de reproducción y la producción lechera del ganado. La publicación de Ecuador **Android Mobile Application for Cattle Body Condition Score Using Convolutional Neural Networks (2023)**²⁷ tiene como objetivo desarrollar una aplicación móvil para Android que evalúe la condición corporal del ganado Bos Taurus mediante técnicas de visión por computadora y deep learning. Para ello se entrenaron tres modelos CNN: Yolo, MobileNet y VGG-16, para diferentes tareas dentro de la App. La aplicación móvil logró una precisión de 0,88 entre la puntuación de condición corporal (BCS) manual y la prevista. Los resultados demostraron que esta aplicación permite a cualquier persona evaluar adecuadamente la condición corporal del ganado utilizando un dispositivo móvil convencional.

El análisis visual de las estructuras ováricas mediante ultrasonido en vacas es una herramienta de apoyo relevante para mejorar el rendimiento reproductivo en el ganado. Sin embargo, en el análisis visual humano, la subjetividad es un factor limitante y las tecnologías de visión por computadora son una forma de superarlo. La publicación de Brasil **Identifying pregnancy in cows using ovarian ultrasound images and convolutional neural networks - a proof-of-concept study (2023)**²⁸ estudia el uso de redes neuronales convolucionales (CNN) para identificar la preñez en vacas mediante imágenes de ultrasonido ovárico obtenidas 30 días después de la inseminación artificial. El conjunto de datos consta de 510 imágenes de ovarios funcionales independientes de 238 vacas Nellore preñadas y 272 no preñadas. Para evaluar la dependencia del rendimiento de CNN en la calidad de la imagen, dos veterinarios independientes con experiencia significativa en evaluación de ultrasonido clasificaron las imágenes como buenas, regulares o malas para la identificación visual de las estructuras ováricas. Se evaluaron cuatro arquitecturas CNN utilizando el conjunto de datos completo y un subconjunto de imágenes buenas y regulares. Se concluye que efectivamente las CNN son una herramienta prometedora para identificar el estado de preñez de las vacas, y que el efecto de la calidad de la imagen en el rendimiento depende de la arquitectura CNN utilizada.

²⁷ [Enlace](#)

²⁸ [Enlace](#)

Las medidas no invasivas desempeñan un papel fundamental en la ganadería y la avicultura de precisión, ya que pueden reducir el estrés de los animales y proporcionar un seguimiento continuo. La actividad animal puede reflejar estados físicos y mentales, así como condiciones de salud.



Si se detecta algún problema, se proporcionará una alerta temprana para las acciones necesarias. En la publicación iraní **Early Detection of Avian Diseases Based on Thermography and Artificial Intelligence (2023)**²⁹, se propone un procedimiento innovador para la identificación oportuna de enfermedades aviares. El objetivo fue identificar enfermedades aviares mediante el uso de procesamiento de imágenes térmicas y machine learning. Se utilizaron cuatro grupos de pollos de engorde, dos grupos fueron infectados con la Enfermedad de Newcastle (ND) e Influenza Aviar (AI), y los otros dos fueron considerados grupos de control. Las imágenes térmicas se capturaron cada 8 h y se procesaron con MATLAB. El marco final basado en SVM logró una precisión del 97,2 % y del 100 % para clasificar la IA y la ND, respectivamente, dentro de las 24 h posteriores a la infección por el virus.

²⁹ [Enlace](#)

2.3.3 SILVICULTURA

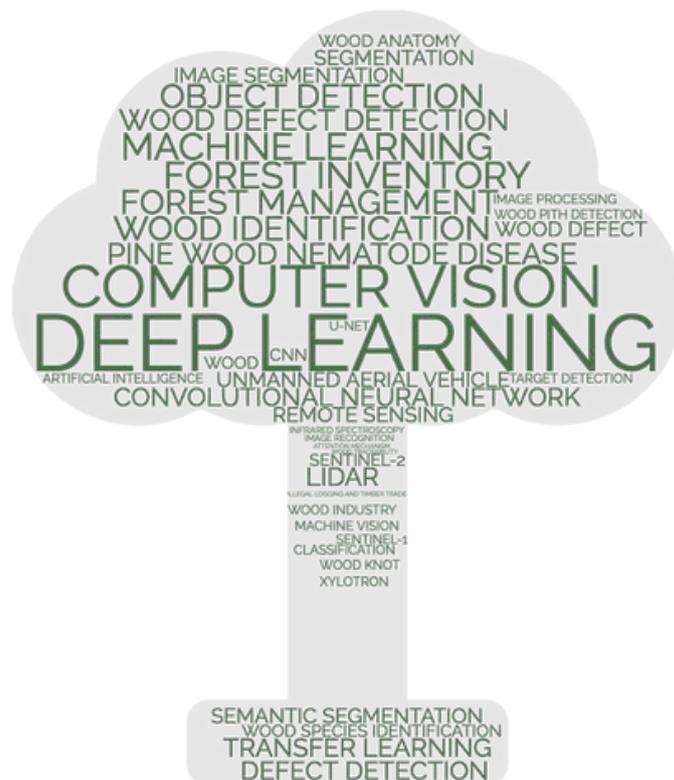
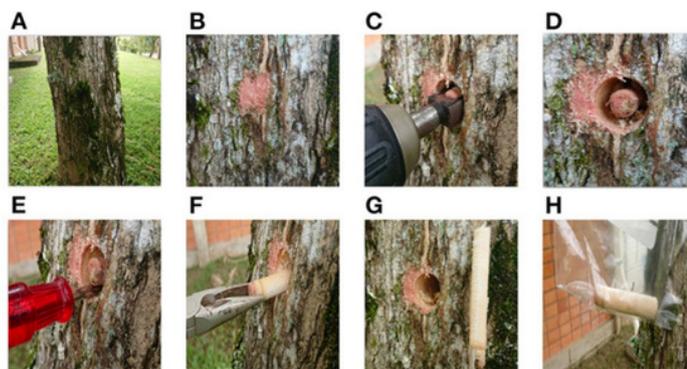


Figura 2.10: Descriptores con mayor frecuencia de aparición en silvicultura
Fuente: IALE Tecnología, elaboración propia

En el sector forestal (ver Figura 2.10), algunas aplicaciones de IA detectadas son 1) identificación y clasificación de especies de árboles y maderas; 2) enfermedades de árboles y maderas; 3) detección de defectos de la madera; 4) trazabilidad de la madera; 5) monitoreo de bosques y detección de incendios forestales. A continuación se presentan publicaciones destacadas en estos temas.

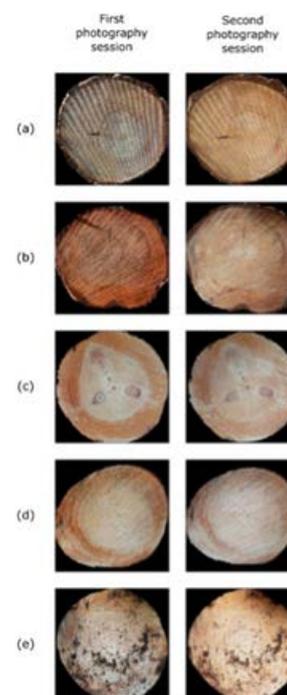
La identificación de especies de árboles es fundamental para apoyar su conservación, su gestión sostenible y, en particular, la lucha contra la tala ilegal. Por lo tanto, es muy importante desarrollar sistemas de identificación rápidos y precisos incluso para los no expertos. En la publicación conjunta entre Costa Rica y Chile **Using Deep Learning to**



Identify Costa Rican Native Tree Species From Wood Cut Images (2022)³⁰, se implementa una CNN y aplicación para identificar especies de árboles nativos de Costa Rica a partir de imágenes de secciones transversales de madera.

³⁰ [Enlace](#)

La identificación de troncos de árboles individuales a lo largo de la cadena de adquisición de madera es un objetivo codiciado dentro de la industria forestal. El rastreo de los troncos desde el bosque hasta el aserradero apoyaría el abastecimiento legal y sostenible de madera, además de aumentar la eficiencia de los recursos y el valor de la madera aprovechada. En la publicación finlandesa **Tree log identification using convolutional neural networks (2023)**³¹ se muestra el desarrollo y evaluación de métodos de identificación de troncos basados en redes neuronales convolucionales profundas. Se utilizó un conjunto de datos de miles de imágenes de extremos de troncos de pino silvestre (*Pinus sylvestris* L.) que muestran diferentes perspectivas, iluminación y efectos de envejecimiento, el cual se encuentra a disposición del público.

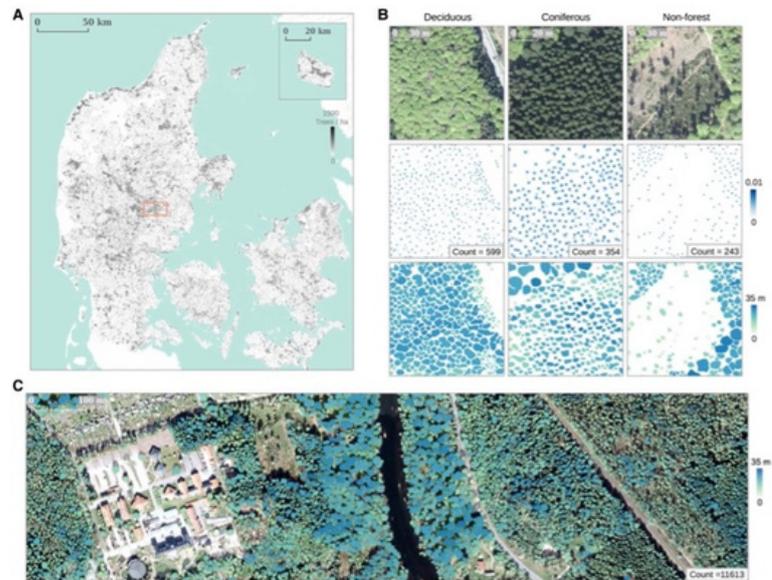


El nematodo de la madera de pino (*Bursaphelenchus xylophilus*) es un patógeno invasor en Corea del Sur, donde ha causado la enfermedad del marchitamiento del pino (PWD) con una mortalidad extremadamente alta de especies nativas de pino (*Pinus densiflora*, *Pinus thunbergii* y *Pinus koraiensis*). Dado que la enfermedad se propaga a través de sus vectores, los escarabajos aserradores de pino nativos (*Monochamus alternatus* y *Monochamus saltuarius*), el costo de monitorear la expansión ha aumentado rápidamente. Además, es aún más costoso eliminar infecciones nuevas y aisladas, ya que los árboles infectados no eliminados actúan como nuevas fuentes de infección debido a la oviposición preferida de los escarabajos en dichos árboles. La metodología de combinación de vehículos aéreos no tripulados (UAV) y detección de objetos basada en el deep learning brinda la oportunidad de resolver dichos problemas, ya que los UAV con cámara RGB pueden proporcionar imágenes aéreas de alta resolución espacial y un modelo de superficie digital (DSM), que se puede utilizar para detección de objetos con excelentes resultados. En la publicación de Corea del Sur **A Monitoring Scheme for Pine Wood Nematode Disease Tree Based on Deep Learning and Ground Monitoring (2023)**³² se presenta un método de monitoreo efectivo y de bajo costo para detectar pinos muertos en áreas dañadas por PWD. Se entrenaron cuatro modelos de detección utilizando cuatro combinaciones diferentes entre imágenes aéreas (R, G, B) y DSM de UAV. Entre ellos, el modelo RGB mostró el mayor rendimiento (recuerdo: 0,9909, precisión: 0,8438) y fue seleccionado como el modelo óptimo.

³¹ [Enlace](#)

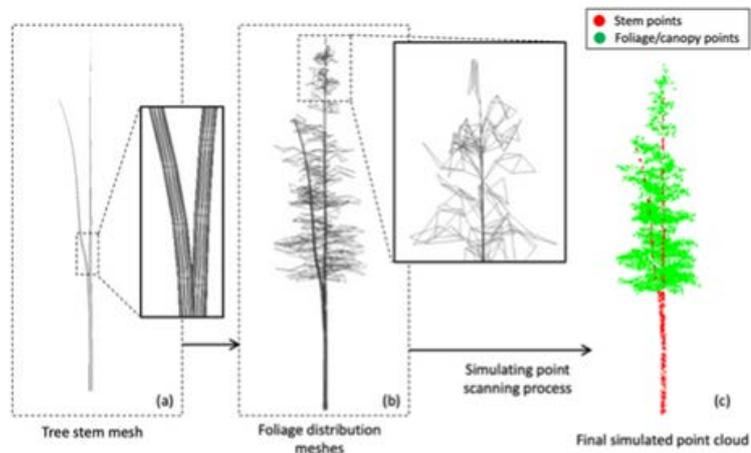
³² [Enlace](#)

La gestión sostenible de los recursos arbóreos es la clave para mitigar el calentamiento climático, fomentar una economía verde y proteger hábitats valiosos. El conocimiento detallado de los recursos arbóreos es un requisito previo para dicha gestión, pero convencionalmente se basa en datos a escala de parcela, que a menudo ignoran los árboles fuera de los bosques. La publicación danesa **Deep learning enables image-based tree counting, crown segmentation, and**



height prediction at national scale (2023)³³ presenta un marco basado en deep learning que proporciona la ubicación, el área de la copa y la altura de árboles individuales a partir de imágenes aéreas a escala nacional. Aplica sobre datos que cubren Dinamarca y muestra que los árboles grandes (diámetro del tallo >10 cm) pueden identificarse con un sesgo bajo (12,5%) y que los árboles fuera de los bosques contribuyen al 30% de la cubierta arbórea total, que normalmente no se reconoce en los inventarios nacionales.

La medición precisa de los parámetros geométricos de los árboles es una parte vital del inventario y manejo forestal. Los sensores aéreos y terrestres de detección y medición de luz (LiDAR) se utilizan actualmente en los inventarios forestales como un medio eficaz y eficiente para la recopilación de datos forestales. Una de las desventajas de estas técnicas en aplicaciones prácticas es el requisito de datos



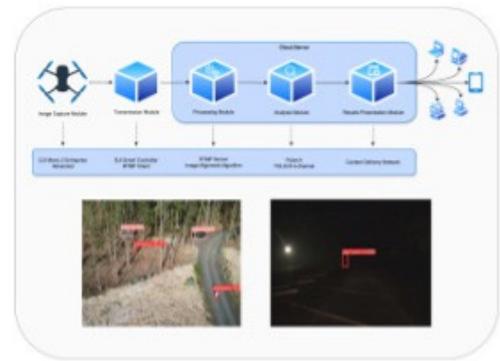
anotados manualmente, necesarios para entrenar las redes neuronales, lo que puede llevar mucho tiempo y ser costoso de lograr. La publicación australiana **Using Synthetic Tree Data in Deep Learning-Based Tree Segmentation Using LiDAR Point Clouds (2023)**³⁴ desarrolla un enfoque para entrenar redes neuronales para la segmentación de troncos de árboles forestales a partir de nubes de puntos que utiliza datos sintéticos de un simulador de árboles personalizado, que puede generar grandes cantidades de ejemplos de entrenamiento sin esfuerzo humano manual. El simulador de árboles captura las características geométricas de los tallos y el follaje de los árboles, a partir de las cuales se pueden generar nubes de puntos sintéticas etiquetadas automáticamente para entrenar un algoritmo de segmentación semántica basado en la arquitectura PointNet++. El código de simulación es de código abierto y está disponible para la comunidad de investigación.

³³ [Enlace](#)

³⁴ [Enlace](#)

Los incendios forestales pueden causar graves pérdidas humanas y económicas, los métodos tradicionales de detección tienen capacidades muy débiles en tiempo real. La nueva generación de tecnología de deep learning proporciona nuevos métodos robustos y precisos. Sin embargo, debido a su gran cantidad de parámetros y cálculos, es difícil de aplicar en la práctica. Con el desarrollo de la edge computing, ahora es posible utilizar edge en vez de cloud para la computación, lo que reduce en gran medida la latencia, mejorando sustancialmente la velocidad de detección de incendios. Así lo demuestra la publicación china **A YOLOv7 Forest Fire Detection System with Edge Computing (2023)**³⁵ que recopila una gran cantidad de imágenes de incendios forestales como un dataset, entrena un modelo para su reconocimiento basado en la red YOLOv7 y luego implementa el modelo entrenado en el servidor perimetral RK3588. Finalmente, se construye una interfaz visual capaz de mostrar resultados de reconocimiento de incendios utilizando Pyqt5.

Los crecientes incidentes de incendios a nivel mundial requieren soluciones efectivas, y la vigilancia forestal emerge como una estrategia crucial. La publicación portuguesa **Applying deep learning to real-time UAV-based forest monitoring: Leveraging multi-sensor imagery for improved results (2023)**³⁶ presenta el desarrollo e implementación de una solución para el monitoreo forestal que abarca desde la transmisión de imágenes capturadas por vehículos aéreos no tripulados (UAV) hasta su análisis con un modelo de detección de objetos sin intervención humana.



Utiliza imágenes del espectro visible e infrarrojo para mejorar la detección de personas y vehículos en entornos forestales. A diferencia de los modelos de visión por computadora existentes que se basan en imágenes de un solo sensor, este enfoque aborda particularmente las condiciones de poca luz, niebla o humo.

³⁵ [Enlace](#)

³⁶ [Enlace](#)

2.3.4 FLORICULTURA

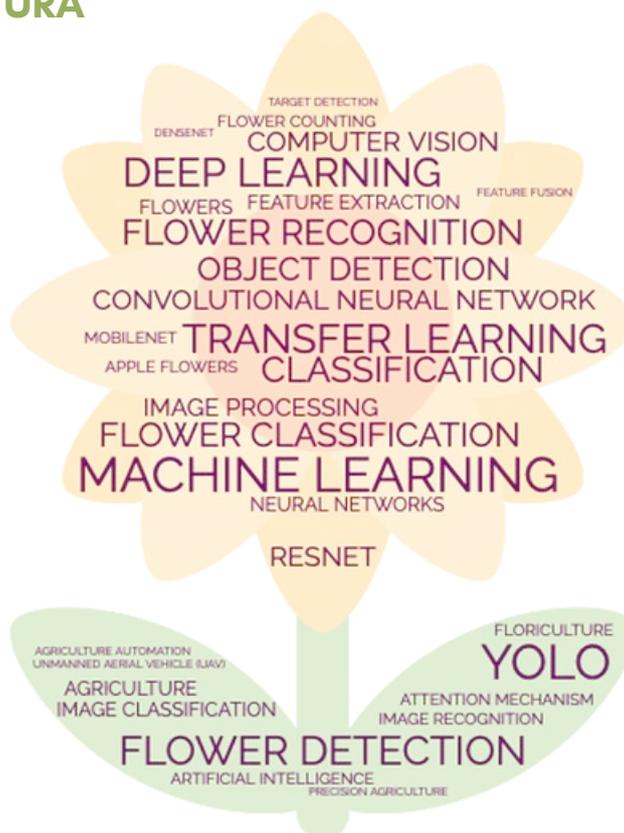
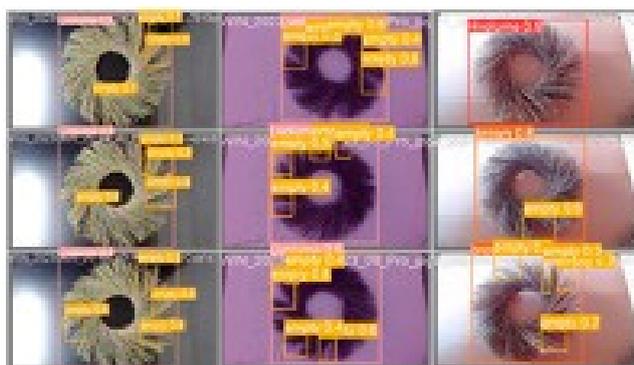


Figura 2.11: Descriptores con mayor frecuencia de aparición en floricultura
Fuente: IALE Tecnología, elaboración propia

En la floricultura (ver Figura 2.11), además de todas aquellas aplicaciones de IA asociadas a agricultura, claramente se visualiza 1) reconocimiento y detección de flores; 2) clasificación de flores; y 3) conteo de flores. Sus publicaciones destacadas son las que se presentan a continuación.

El aseguramiento de la calidad mediante la inspección visual juega un papel fundamental en la agricultura. En los últimos años, las técnicas de aprendizaje profundo (DL) han demostrado resultados prometedores en el reconocimiento de objetos. A pesar de este progreso, pocos estudios se han centrado en evaluar la inspección visual humana y la DL para la identificación de defectos.



La publicación mexicana **An Assessment of Human Inspection and Deep Learning for Defect Identification in Floral Wreaths (2023)**³⁷ hace una evaluación entre la inspección visual humana y el uso de DL para la identificación de defectos en productos de la industria de la floricultura utilizando una muestra de coronas florales decorativas defectuosas y correctas. Los resultados evidenciaron que los modelos presentaron un rendimiento similar al de los humanos en términos de precisión y exactitud, destacando la idoneidad de DL para ayudar a los humanos a identificar defectos en productos de floricultura elaborados artesanalmente.

³⁷ [Enlace](#)



Las flores tienen un gran valor cultural, económico y ecológico en nuestra vida. La clasificación precisa de las flores facilita diversas aplicaciones de la floricultura. Sin embargo, los conjuntos de datos existentes para la tarea de clasificación visual se centran principalmente en imágenes RGB comunes. Limita la aplicación de poderosas técnicas de aprendizaje profundo en dominios específicos como el análisis espectral de flores. En la publicación china **A large-scale hyperspectral dataset for flower classification (2022)**³⁸ recopilaron un conjunto de datos de imágenes hiperespectrales de flores a gran escala llamado HFD100 para la clasificación de flores, con más de 10.700 imágenes pertenecientes a 100 categorías. Luego realizaron varios experimentos de referencia en este data set cumpliendo el desafío de variación inter e intra clases.

Existen miles de especies y colores diferentes de flores. Identificar cada una de ellas requiere un botánico con inmensos conocimientos y capacidades. La introducción de algoritmos de aprendizaje de sistemas que consisten en redes neuronales convolucionales para descubrir especies de flores con una fotografía sería una gran ayuda para industrias como la farmacéutica y la cosmética. La publicación india **Deep Learning Based Model for Multi-classification of Flower Images (2023)**³⁹ intenta introducir redes neuronales convolucionales para seleccionar flores simplemente alimentando una fotografía de la flor para ser reconocida.



La publicación tailandesa **Quality grading of crown flowers using Convolutional Neural Network (2023)**⁴⁰ presenta una clasificación de imágenes para medir la calidad de flores para coronas utilizando una red neuronal convolucional y aprendizaje por transferencia. Utilizando datos de 1.500 flores de corona blanca, se dividieron en cinco clases de la siguiente manera: 1) flores con la base de los pétalos muy juntas, 2) flores con moho, 3) flores con más de un rasgo negativo, 4) flores con desigual longitud del pétalo, y 5) flor completa. Se experimentó con cuatro modelos, cuyos resultados muestran una mayor precisión, recuperación y puntuación F1 del modelo y se puede aplicar para clasificar la calidad de las flores de coronas, lo que ayuda a los jardineros a clasificar las flores de manera más eficiente.

³⁸ [Enlace](#)

³⁹ [Enlace](#)

⁴⁰ [Enlace](#)



3. Conclusiones

El presente informe ha seguido los lineamientos metodológicos de la Vigilancia Tecnológica consistente en un proceso de preparación, búsqueda, captura, procesamiento y análisis de información científica asociada a Inteligencia Artificial (IA) aplicada al sector silvoagropecuario.

La curva exponencial de la producción científica de la última década refleja un enorme esfuerzo en cuanto al desarrollo de esta nueva disciplina, nuevos métodos y arquitecturas, además de tratar de resolver los problemas que aún tiene la IA, como por ejemplo los modelos que todavía no son explicables, es decir lo que funciona bien pero no se puede explicar por qué funciona bien, y así evitar comportamientos negativos o resultados no deseados. Además, cuando hay un desarrollo fuerte en la disciplina misma de la IA y estos desarrollos se trasladan a las aplicaciones, por ejemplo en este caso a la agricultura, la producción científica es todavía mayor, generando un efecto multiplicador.

En lo específico, la captura y análisis de información se realizó para los últimos cinco años (2019-2023), identificando un total de 4.900 publicaciones científicas, las cuales se distribuyen de manera creciente en el periodo analizado. En este ámbito, de un total de 77 países, destacan como líderes indiscutidos China e India con el 53% de las publicaciones identificadas en el área de interés. Le sigue Estados Unidos con 448 publicaciones, y muy por debajo los países de Arabia Saudita, Corea del Sur, Japón y países europeos. Destaca la presencia de Brasil entre los 16 países líderes, con más de 90 publicaciones. En Centro y Sudamérica, el líder indiscutido es Brasil con 98 publicaciones, seguido muy por debajo de México, Colombia, Perú, Ecuador, Chile, Argentina, Costa Rica, Uruguay, Panamá y Honduras.

Para el caso particular de Chile, se identificaron ocho trabajos vinculados a instituciones nacionales, de los cuales cinco de ellos se han desarrollado en colaboración con instituciones de Estados Unidos, México, Costa Rica, Brasil y España. La publicación más reciente (2023) corresponde al trabajo conjunto entre la Universidad Técnica Federico Santa María, la Universidad de Los Andes y la Universidad de California, la cual presenta una comparación exhaustiva de cinco estrategias de deep learning aplicadas al recuento de manzanas en los árboles.

Respecto a las instituciones líderes, con treinta o más publicaciones, en el top se encuentra el Ministerio de Agricultura de China, luego destacan principalmente instituciones académicas chinas e indias. Le siguen universidades e institutos de Estados Unidos, Australia, Japón y Europa. Además de universidades destacan algunos centros de investigación, como ICAR de India, EMBRAPA de Brasil, CSIRO de Australia con oficinas en Chile, CNR de Italia, entre otros.

Para efectos de análisis, se dividió el corpus de información en las cuatro áreas del sector silvoagropecuario definidas de interés: agricultura, ganadería, silvicultura y floricultura, detectando en cada una de estas áreas, diversas aplicaciones y trabajos de investigación destacadas.



Entre las múltiples aplicaciones de IA identificadas en el área de Agricultura, se encontraron trabajos en detección, identificación, clasificación, predicción, monitoreo, deficiencia de nutrientes relacionadas a enfermedades y plagas de plantas. Otros trabajos científicos esta vez aplicado a Frutas, con temas de detección, reconocimiento, clasificación y ordenamiento, así como trabajos en Robótica agrícola y picking.

En el sector Ganadero se identificaron aplicaciones de IA como identificación, detección y seguimiento del ganado; también trabajos en relación al comportamiento y al bienestar animal, así como reconocimiento y detección de rostros.

En el sector Forestal algunas aplicaciones de IA fueron, identificación y clasificación de especies de árboles y maderas; enfermedades de árboles y maderas; detección de defectos de la madera; trazabilidad de la madera; monitoreo de bosques y detección de incendios forestales.

En la Floricultura, además de todas aquellas aplicaciones de IA asociadas a agricultura, se identificaron trabajos en temas vinculados al reconocimiento y detección de flores; clasificación y conteo de flores.

Según las áreas de interés identificadas, se aprecia que en general la IA en agricultura requiere un aprendizaje del tipo supervisado, calzando en la taxonomía de Clasificación según el esquema presentado en el capítulo 1.1 de este informe. Los dataset son principalmente imágenes, etiquetadas por técnicas de Machine Vision y Object Vision. Así, la investigación científica hasta aquí se ha centrado en el desarrollo de algoritmos, generación de dataset, algunos de los cuales son de uso público, y selección del modelo más apropiado.

4. Bibliografía

[1] Rousseau, P.L. (2010). general purpose technologies. In: Durlauf, S.N., Blume, L.E. (eds) Economic Growth. The New Palgrave Economics Collection. Palgrave Macmillan, London. https://doi.org/10.1057/9780230280823_11

[2] Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). GPTs are GPTs: An Early Look at the Labor Market Impact Potential of Large Language Models. ArXiv. /abs/2303.10130

[3] A scientific software ecosystem architecture for the livestock domain (2023). [Enlace](#)

[4] Non-contact sensing technology enables precision livestock farming in smart farms (2023). [Enlace](#)

[5] Analysis of the drivers of Agriculture 4.0 implementation in the emerging economies: Implications towards sustainability and food security (2023). [Enlace](#)

[6] Agriculture paradigm shift: a journey from traditional to modern agriculture (2024). [Enlace](#)

[7] Machine learning for weed-plant discrimination in agriculture 5.0: An in-depth review (2023). [Enlace](#)

[8] Enhancing smart farming through the applications of Agriculture 4.0 technologies (2022). [Enlace](#)

[9] Exploring artificial intelligence for applications of drones in forest ecology and management (2024). [Enlace](#)

[10] Automatic trait estimation in floriculture using computer vision and deep learning (2024). [Enlace](#)

[11] Artificial Intelligence as a Tool in Floriculture Research (2023). [Enlace](#)

