

Aplicaciones de la Inteligencia Artificial en Microbiología

Agroambiental

Applications of Artificial Intelligence in Agro-Environmental

Microbiology

Brayan Steven Cruz Florez^{1*}
Blair Ricardo Gomez Torres¹
Ligia Consuelo Sanchez Leal¹

*Contacto correspondencia: bcruz@unicolmayor.edu.co

¹Colombia

Resumen

La inteligencia artificial (IA) ha pasado de ser un concepto futurista a ser una realidad que ha emergido en la última década como uno de los avances más significativos, transformándose así en una gran herramienta que ha visto un incremento en su uso en distintos campos de la ciencia y tecnología marcando un hito en el paso a una nueva revolución tecnológica. Entre estas áreas del conocimiento, las ciencias ambientales particularmente la microbiología agroambiental se ha convertido en uno de los campos donde las aplicaciones de la IA han tenido relevancia. De esta forma, esta nueva tecnología a partir de diferentes métodos como el aprendizaje automático o el aprendizaje profundo ofrece soluciones innovadoras que son aplicables para monitorear y gestionar los distintos sistemas que se pueden encontrar dentro de lo que comprende la microbiología agroambiental. Esta investigación se centró en la búsqueda de las distintas aplicaciones que puede tener la IA y que pueden ser aplicables en procesos propios de la microbiología ambiental, la agricultura y sanidad de los cultivos, la biorremediación y la sostenibilidad ambiental, todos ellos considerados parte fundamental para la comprensión de lo que es el área agroambiental. En esta investigación, se realizó la búsqueda en distintas bases de datos para encontrar la información, logrando así establecer los principios básicos para la comprensión de las herramientas de la IA y cuál es su aplicabilidad dentro de la microbiología agroambiental esta área, resaltando los beneficios de la incorporación de estas tecnologías y sus perspectivas futuras.

Palabras claves:

Inteligencia artificial; Aprendizaje Automático, Aprendizaje Profundo, Microbiología Ambiental, Agricultura, Biorremediación, Sostenibilidad Ambiental

Abstract

Artificial intelligence (AI), a concept that has emerged in the last decade as one of the most significant advances, thus becoming a great tool that has seen an increase in its use in different fields of science and technology, marking a milestone on the road to a new technological revolution. Among these areas of knowledge, environmental sciences, particularly agri-environmental microbiology, have become one of the fields where AI applications have been relevant. In this way, this new technology based on different methods such as machine learning or deep learning offers innovative solutions that are applicable to monitor and manage the different systems that can be found within what comprises agro-environmental microbiology. This research focused on the search for the different applications that AI can have and that can be applicable in different processes such as studies of environmental microbiology, agriculture and crop health, bioremediation and environmental sustainability, all of them, processes that are considered a fundamental part to understand what the agro-environmental area is. In this research, an exhaustive search was carried out in different databases to find the information, thus establishing the basic principles to understand AI tools and what their applicability is within this area, highlighting what the benefits have been of the incorporation of these technologies and the future perspectives on them.

Keywords:

Artificial intelligence; Machine Learning; Deep Learning; Environmental Microbiology; Agriculture; Bioremediation; Environmental sustainability

Introducción:

En la última década, la inteligencia artificial (IA) pasó de ser un concepto futurista para ser una realidad que ya tiene un impacto en distintos aspectos de la vida cotidiana, desde asistentes virtuales en los dispositivos móviles hasta algoritmos avanzados que impulsan decisiones en sectores de la medicina, la industria y la economía, entre otros. La IA se ha impuesto como un pilar fundamental de la era digital. El campo de interés en este artículo de revisión es la microbiología agroambiental, una rama de la microbiología que se centra en el estudio de los microorganismos presentes en el ambiente agrícola y su interacción con los cultivos, suelos y sistemas de producción agrícola, así como los efectos en los recursos naturales que componen un ecosistema y un agroecosistema. A través del uso de IA, es posible tener una mejor perspectiva de soluciones para mejorar la calidad de los procedimientos en esta área y comprender mejor las interacciones entre la agricultura y el desarrollo sostenible, así como la interacción que los seres humanos tienen con estos sistemas.

Los microorganismos hacen parte de la historia del planeta tierra mucho antes que cualquier otro ser vivo, este recorrido histórico, se torna interesante cuando el hombre empieza a entender el comportamiento bioquímico que le permite aprovechar una amplia variedad de fuentes de energía y que en esencia es lo que define su diversidad a nivel funcional, estructural y su capacidad de adaptabilidad eficiente en cualquier medio (Noé Manuel Montañón et al., 2010). Adicionalmente, sus características le permiten estar en cualquier tipo de ambiente y establecer una interacción de manera directa o indirecta con el medio, el cual puede modificar o influir ya sea en forma benéfica, neutra o perjudicial en el ambiente que utilice como hábitat. A manera conceptual, estas interacciones ambiente - microorganismo harán parte de lo que se denomina Microbiología Agroambiental (Kapur, 2019).

El ambiente como término, abarca mucho más de lo que se observa a simple vista en un medio natural, además de representar todo lo que hace parte en un entorno y por lo que se encuentra compuesto, incluirá también las interacciones que surgen por una variedad de factores encontrados en este espacio, que se encuentran interconectados entre sí y logran generar un impacto en él (Chu & Karr, 2017). Normalmente, hay una sinergia que permite establecer un equilibrio en estas interacciones y este estado en un ambiente se podría considerar normal, generando beneficios sin perjudicar algún proceso o interacción que hagan parte de él. Sin embargo, ya sea por la inclusión de un factor adicional o un desbalance en alguna interacción puede provocar que esta sinergia se desestabilice, provocando un desequilibrio que puede generar un cambio radical en este entorno. De esta manera, este desequilibrio genera aquellas interacciones negativas que pueden causar impactos como la contaminación, el calentamiento global, afectaciones de distintos ecosistemas, cambios poblacionales o afectaciones de los cultivos. Es aquí donde, la microbiología agroambiental surge como aquella área en donde se abordan todas estas componentes, comprendiendo que todo se correlaciona y que tanto aquella vida microscópica como la vida de los seres humanos está íntimamente ligada y que cualquier acción de uno de sus componentes tiene un efecto en la otra (Gupta et al., 2017).

La inteligencia artificial (IA) actualmente representa uno de los avances más grandes en cuanto a la innovación tecnológica (Krenn et al., 2022) al simular la complejidad de la mente humana a través de sistemas computacionales y máquinas (Sheikh et al., 2023). Si se habla de cuál es el propósito en general de la IA, este sería el de simular las capacidades cognitivas humanas (Krenn et al., 2022), integrando desde la percepción hasta el razonamiento (Krenn et al., 2022), el aprendizaje (Krenn et al., 2022) y la toma de decisiones (Krenn et al., 2022). Este campo de estudio de la IA surge de la necesidad de crear tecnologías que puedan realizar distintas tareas complejas de manera autónoma, mejorando así la eficiencia y la precisión en diversos ámbitos donde se apliquen dichas tareas; por lo tanto, la IA se ha vuelto cada vez más relevante en la evolución tecnológica (Krenn et al., 2022), y, así como se han presentado momentos en la historia como el surgimiento de las máquinas de vapor o el uso de la electricidad y que han marcado un antes y un después en el camino hacia una nueva era de innovación y avances, la IA está marcando tendencias que a futuro tienen gran potencial.

En este contexto, la investigación en IA abarca una diversidad de áreas, incluyendo algoritmos de búsqueda (Mukhamediev et al., 2022), procesamiento de lenguajes naturales (Mukhamediev et al., 2022), aprendizaje automático (ML, por sus siglas en inglés, *Machine Learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), aprendizaje profundo (DL, por sus siglas en inglés, *Deep Learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), entre otras. Todos estos avances tecnológicos están soportados por una red de infraestructura que integra datos, almacenamiento, potencia informática y algoritmos avanzados, y es así como por

medio de estos factores se desarrollan aplicaciones más avanzadas y útiles que a su vez pueden ejecutar tareas más complejas que hacen aportes aún mayores en el área donde se utilicen.

Se podría decir dentro del ámbito de la IA, que se puede dividir en dos componentes importantes: el primero sería el aprendizaje automático (ML) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022) y el segundo, que sería aprendizaje profundo (DL) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022). Si bien, se puede entender que el aprendizaje profundo es parte del aprendizaje automático (Mukhamediev et al., 2022; Holzinger et al., 2023; Holzinger et al., 2023; Francisco Castillo Díaz, 2022), ambos tienen sus propios conjuntos de algoritmos, sus propias características y también su propio sistema de cálculo con el cual se desarrollan modelos expertos para proyecciones y clasificaciones con una mayor precisión (Holzinger et al., 2023).

Los sistemas de IA de igual manera se pueden categorizar en diferentes tipos y subcategorías (Holzinger et al., 2023), (Francisco Castillo Díaz, 2022). En esta clasificación, se destacan la IA débil o estrecha (en inglés, *Artificial Narrow Intelligence*, ANI) (Holzinger et al., 2023; Francisco Castillo Díaz, 2022), cuya función principal se centra en ejecutar tareas específicas y que es comúnmente encontrada en herramientas como los asistentes virtuales comunes en un dispositivo móvil (Francisco Castillo Díaz, 2022). Por otro lado, está la IA fuerte, modelo, la cual todavía se puede decir que se encuentra en fase de desarrollo y que se subdivide en IA fuerte general (en inglés, *Artificial General Intelligence*, AGI) (Holzinger et al., 2023; Francisco Castillo Díaz, 2022) e IA fuerte superior (en inglés, *Artificial Super Intelligence*, ASI) (Francisco Castillo Díaz, 2022). Idealmente, la AGI aspira a simular la mente y el razonamiento del ser humano (Holzinger et al., 2023; Francisco Castillo Díaz, 2022), mientras que con la ASI se espera superar incluso la capacidad intelectual humana, planteando así el gran potencial que podría abarcar para la próxima revolución industrial (Francisco Castillo Díaz, 2022) pero que a su vez es uno de los grandes problemas éticos que se pueden plantear cuando se piensa en la IA (Francisco Castillo Díaz, 2022).

El desarrollo de la IA, al estructurar varios campos de investigación (Xu et al., 2021), permite que se articulen en torno a la inteligencia perceptiva (Krenn et al., 2022; Xu et al., 2021), cognitiva (Krenn et al., 2022; Xu et al., 2021) y para la toma de decisiones (Krenn et al., 2022; Xu et al., 2021), comprendiendo así que la inteligencia perceptiva engloba las capacidades básicas de percepción (Xu et al., 2021), como la visión (Xu et al., 2021), audición (Xu et al., 2021) y tacto (Xu et al., 2021). Por su parte, la cognitiva se relaciona con la inducción, razonamiento y la adquisición de conocimientos. En cuanto a la inteligencia relacionada con la toma de decisiones (Xu et al., 2021), implica la aplicación de la ciencia de datos, las ciencias sociales y la teoría de la decisión se utilizan para optimizar las decisiones (Krenn et al., 2022; Xu et al., 2021). De esto último surgen problemas éticos, e incógnitas como ¿Cuál es el grado de fiabilidad en la toma de decisiones de una IA?. Este representa uno de los factores adversos al pensar en la aplicación de esta tecnología, por lo que se plantea como reflexión, en qué casos resulta viable aplicar la toma de decisiones de la IA y en cuáles no (Sheikh et al., 2023).

Resulta importante destacar que, si bien la IA ha logrado avances significativos, aún existen desafíos y debates sobre su desarrollo ético (Sheikh et al., 2023), así, otras problemáticas que surgen como el impacto en el empleo y cuáles son los potenciales riesgos de optar por el uso de estas tecnologías sobre tecnologías más tradicionales en distintas áreas (Mukhamediev et al., 2022). Sin embargo, ya no hay punto de retorno en el crecimiento continuo de este campo, el cual promete seguir impulsando la innovación y el progreso en el futuro (Krenn et al., 2022; Mukhamediev et al., 2022).

¿Podría entonces la inteligencia artificial ser aplicada en cualquier área? Sí, la IA se puede aplicar en cualquier área, gestionándola de manera adecuada; la IA tiene alcances prácticamente ilimitados y por ello en este artículo se revisará su aplicación en la microbiología agroambiental (Francisco Castillo Díaz, 2022). En un mundo donde se tiene un impacto que parece irreversible cuando se habla de seguridad alimentaria (Ding et al., 2023), calentamiento global, globalización, manejo de los residuos y la contaminación, la inteligencia artificial y su inminente llegada para quedarse (Holzinger et al., 2023), surgen como una forma inteligente para buscar soluciones a estas problemáticas y por eso la IA ofrece nuevas alternativas para dar respuesta en el área de la microbiología agroambiental (Holzinger et al., 2023).

En este artículo, se observarán los resultados de una revisión en la que se tuvo como objetivo establecer aplicaciones de la IA en la microbiología agroambiental. Se establecieron las distintas herramientas que ofrece la inteligencia artificial y que pueden ser utilizadas en la microbiología, las cuales aportan al estudio y análisis en la microbiología ambiental, comprendiendo el conocimiento sobre microbiomas y biodiversidad microbiana, así como la monitorización de la calidad de ambientes como agua y suelo y las aplicaciones de la IA en la agricultura y sanidad de los cultivos. También se analizó cómo la IA se utiliza en el modelado y asistencia en procesos de biorremediación y finalmente, utilización de la IA en la optimización y la predicción de decisiones de implementación en sostenibilidad ambiental.

Metodología

Se llevó a cabo una revisión exhaustiva en diversas bases de datos y en distintas fuentes de información que abarcaran aplicaciones de la inteligencia artificial en el nexo microbiología-ambiente – agricultura - desarrollo sostenible. Se buscaron, identificaron y leyeron artículos publicados, reportes de casos y capítulos de libros, que se obtuvieron específicamente en las bases de datos de Sciencedirect (<https://www.sciencedirect.com/>), NCBI (<https://www.ncbi.nlm.nih.gov/>), MDPI (<https://www.mdpi.com/>), Nature (<https://www.nature.com/natrevphys/>), Frontiers (<https://www.frontiersin.org/>), Springerlink (<https://link.springer.com/>), Crossref (<https://www.crossref.org/>). Para la búsqueda se utilizó una serie de palabras clave, así como el uso de operadores booleanos para cubrir la búsqueda así: “artificial intelligence AND environmental microbiology”, “artificial intelligence AND corps”, “artificial intelligence AND plants AND microbiology”, “artificial intelligence AND plants AND microorganisms”, “artificial intelligence AND environmental microorganisms”, “artificial intelligence AND bioremediation”, “artificial intelligence AND ecology”.

Generalidades

¿Qué es la Inteligencia Artificial?

La inteligencia artificial es definida de muchas formas y por lo tanto no existe una única forma de denotar este término (Sheikh et al., 2023), pero si se puede tener una comprensión sobre que es una IA. De acuerdo con lo revisado, los autores de este artículo establecen que la IA consiste en una serie de distintos algoritmos los cuales tienen como finalidad imitar el actuar humano (Krenn et al., 2022; Mukhamediev et al., 2022), es decir, replicar su racionalidad y pensamiento (Krenn et al., 2022; Xu et al., 2021). En este sentido, se puede decir que la IA se basa en aprender, razonar, actuar y decidir (Krenn et al., 2022; Xu et al., 2021; Robinson, 2022). De hecho, comprender la IA de esta forma, permite establecer que esto funciona de manera cíclica (figura 1), a través de la cual se obtienen unos resultados los cuales, son usados en el área donde se aplica la IA. Un ejemplo de esto puede ser el uso actual del ChatGPT, donde a través de Prompts (Walsh et al., 2024) (comandos) se puede ejercer toda la actividad cíclica de aprender, razonar, decidir y actuar, a partir de un comando escrito por la persona que está usando ChatGPT. Los algoritmos de esta IA generan un resultado que es la respuesta de este chatbot, en donde puede aprender partiendo de los prompts que se le escriben y respecto a los mismos razona, decide y actúa, generando así el resultado esperado que va a ser la respuesta en el chat.




Figura 1. Funcionamiento cíclico de comprensión de la IA

Herramientas de inteligencia artificial

1. Aprendizaje Automático y Aprendizaje Profundo

La IA tiene dos ramas principales que son, el aprendizaje automático (ML) y el aprendizaje profundo (DL) (Mukhamediev et al., 2022; Holzinger et al., 2023; Francisco Castillo Díaz, 2022). Cuando se habla de ML se refiere a un tipo de entrenamiento (Holzinger et al., 2023), mientras que cuando se habla de DL este se asocia más redes neuronales artificiales (en inglés, *Artificial neuronal networks*, ANNs). Su utilidad radica en el manejo de gran cantidad de datos (Holzinger et al., 2023; Pichler & Hartig, 2023), pero es importante tener en cuenta que estos conceptos no se consideran por aparte, sino que de hecho el DL hace parte del ML, por lo que se puede decir que el DL se establece como una alternativa para aumentar la efectividad del ML (Pichler & Hartig, 2023) y lograr el objetivo de la IA.

ML es una serie de métodos que permiten predicción de ciertas características de un grupo de datos a partir del entrenamiento que se ha tenido respecto a estos mismos datos, es decir, aprender y analizar los datos para posteriormente predecir eventos con ellos (Sun et al., 2022; Goodswen et al., 2021). De esta manera, tenemos que el ML sienta bases en el entrenamiento con datos (Goodswen et al., 2021; Walsh et al., 2024; Pichler & Hartig, 2023), por lo cual, para desarrollar un modelo de ML se entrena utilizando un grupo de datos y estos mismos contienen información para que el modelo aprenda a hacer su predicción. A lo largo de este proceso, se puede lograr ajustar el modelo para que a medida que aprenda se minimicen los errores y así a su vez se mejore la capacidad para predecir a partir de patrones (Goodswen et al., 2021, Zhao et al., 2023; Pichler & Hartig, 2023), todo esto con el fin de que cuando sea sometido a nuevos datos a partir del aprendizaje previo, tenga la capacidad de predicción.

El DL es considerado, en sí mismo, una rama del ML (figura 2) que se centra en el entrenamiento de modelos de IA para realizar tareas cada vez más complejas (Zhao et al., 2023; Jiang et al., 2022; Pichler & Hartig, 2023). Se le relaciona con el concepto de “profundo” porque implica el uso de redes neuronales, que son modelos con múltiples capas de procesamiento (Sun et al., 2022). Estas redes tienen la capacidad de aprender jerárquicamente la representación de un conjunto de datos, lo que les permite capturar características y patrones de manera automática a partir de conjuntos de datos extensos y complejos (Sun et al., 2022; Zhao et al., 2023; Liang et al., 2020).

Los métodos que utiliza el ML se pueden dividir según el método de aprendizaje y el propósito del algoritmo que se utiliza (Goodswen et al., 2021); entre estos está el aprendizaje supervisado (SL, por sus siglas en inglés, *supervised learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023; Zhao et al., 2023), el aprendizaje no supervisado (UL, por sus siglas en inglés, *unsupervised learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023), semi-aprendizaje supervisado (SSL, *semi-supervised learning*) (Mukhamediev et al., 2022), aprendizaje reforzado (RL, en inglés, *reinforcement learning*) (Mukhamediev et al., 2022; Holzinger et al., 2023) y el aprendizaje profundo (DL) (figura 2) (Mukhamediev et al., 2022; Holzinger et al., 2023; Zhao et al., 2023)




Figura 2. Diagrama que representa la relación entre la IA, el ML, DL, SL, UL, SSL y RL

El ML se posiciona así como un gran avance con amplios usos en diversas áreas entre ellos la microbiología y los estudios agroambientales, donde los modelos predictivos que se obtienen a partir del ML tienen una aplicación (Walsh et al., 2024), por ejemplo al permitir un análisis de rasgos microbianos (Ghannam & Techtmann, 2021; Peyman Namadi & Deng, 2023; Asala Mahajna et al., 2022), actores ambientales (Ali et al., 2023; Walsh et al., 2024; Liang et al., 2020; Asala Mahajna et al., 2022) y respuestas de las plantas al momento de la predicción de cepas microbianas en la relación de interacción planta-microbio-suelo (Miller et al., 2023; Ali et al., 2023, Walsh et al., 2024; Liang et al., 2020), así como también entra en juego el DL, ya que al gestionar el manejo de datos de microorganismos permite descubrir patrones y relaciones ocultos y hacer predicciones (Miller et al., 2023; Ali et al., 2023; Liang et al., 2020).

De esta manera, el uso de estos modelos basados en IA, permiten mejorar dos factores fundamentales en procesos experimentales dentro de investigaciones de cualquier área, incluyendo la microbiología, que son la eficiencia y eficacia (Miller et al., 2023; Ali et al., 2023; Zhao et al., 2023; Robinson, 2022; Kumar et al., 2023), ya que la aplicación de esta nueva tecnología facilita esa acción de prueba y error que es común en el trabajo de investigación y que requiere mucho tiempo. La utilización de estos modelos mejora estos procesos al facilitar la toma de decisiones, al predecir resultados y de esa manera gestionar una actividad (Ali et al., 2023), ya sea dentro de la investigación, o inclusive en la toma de decisiones en el área del desarrollo sostenible (Miller et al., 2023; Wu & Zhao, 2023; Chowdhury et al., 2024), sanidad ambiental (Asala Mahajna et al., 2022), diagnóstico en el laboratorio (Egli et al., 2020; Shelke et al., 2023; Ihsan et al., 2023; Ghannam & Techtmann, 2021; Peyman Namadi & Deng, 2023) y la agricultura (Miller et al., 2023; Wu & Zhao, 2023; Spyridon Mourtzinis et al., 2021; Lu et al., 2024). De esta manera, es como el ML toma un papel fundamental y el conocimiento de sus diversos modelos facilita su adecuación a cualquier actividad.

Estos modelos han generado con su implementación cambios en la manera de realizar las tareas que podían ser repetitivos promoviendo una automatización basada en IA, por tal razón, se puede hablar de la entrada en la época de la “microbiología digital” (Ali et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), en donde ya se ha puesto en marcha el apoyo de chatbots en el laboratorio (Egli et al., 2020), microscopía automatizada (Egli et al., 2020; Zhang, Li, et al., 2023), sistemas automatizados de lecturas de placas (Egli et al., 2020), lectura de pruebas en equipos electrónicos (Egli et al., 2020; Ihsan et al., 2023), aplicaciones de análisis en metagenómica (Kumar et al., 2023) y toma de decisiones post análisis (Miller et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), facilitando así la investigación microbiana (Jiang et al., 2022; Asala Mahajna et al., 2022) en cuanto al diagnóstico (Egli et al., 2020; Shelke et al., 2023; Ihsan et al., 2023; Ghannam & Techtmann, 2021), identificación (Shelke et al., 2023; Zhao et al., 2023; Walsh et al., 2024; Ihsan et al., 2023; Ghannam & Techtmann, 2021) y caracterización (Ihsan et al., 2023; Ghannam & Techtmann, 2021; Liang et al., 2020) de microorganismos particulares (Peyman Namadi & Deng, 2023) y comunidades microbianas (Ghannam & Techtmann, 2021; Kumar et al., 2023).

2. Redes neuronales

Cuando se habla de DL, se hace referencia a un grupo de ANNs que están compuestas por capas ocultas (Sun et al., 2022; Peyman Namadi & Deng, 2023). El DL se puede utilizar de forma supervisada, no supervisada y semisupervisada (Zhao et al., 2023).

En este orden de ideas, el DL es aquella rama de la IA que más crecimiento ha tenido en estos últimos años; estas ANN están inspiradas en el cerebro del ser humano y tratar de imitar lo que serían las conexiones neuronales, estas redes contienen unidades que trabajan en conjunto para procesar la información que conforman capas (Zhao et al., 2023; Zhang, Li, et al., 2023). Cuando se habla de capas en una ANN, que es la manera más común en que se organizan, representan el flujo de la información (Zhao et al., 2023), ya que existe una capa de entrada que recibe los datos y está a su vez transmite la información a través de una o varias capas que se denominan “ocultas” para finalmente llegar a una capa de salida que ya es el sitio donde se obtienen los resultados esperados (figura 3) (Zhao et al., 2023)




Figura 3. Diagrama de representación del funcionamiento básico de una ANN

Por lo tanto, se puede ver que cada unidad está conectada a través de enlaces, a través de los cuales se transmiten las señales (Zhang, Li, et al., 2023), a lo largo del paso por la red neuronal, la información de entrada sufre cierto tipo de alteraciones que generan los valores de nueva forma para su salida (Sun et al., 2022; Ali et al., 2023). El principal objetivo de una ANN se basaría en resolver los problemas imitando un cerebro humano, esto se entiende a manera de que, como seres humanos al recibir un estímulo por cualquiera de los sentidos se expresa una serie de reacciones bioquímicas que pasan por el sistema neuronal y acaban resultando en un efecto ya sea dolor, sorpresa, análisis, reflexión, entre otros. En concreto, en la ANN se busca imitar haciendo uso de millones de unidades neuronales por donde la información transita posterior a una entrada en el mismo sistema de la ANN (Mukhamediev et al., 2022, Zhao et al., 2023; Zhang, Li, et al., 2023).

De esta manera, las ANN como eje fundamental del DL (Mukhamediev et al., 2022; Chowdhury et al., 2024), hacen parte del ML, razón por la cual su entrenamiento es fundamental para su correcto funcionamiento (Mukhamediev et al., 2022; Ihsan et al., 2023). Este entrenamiento radica en la utilización de datos de entrada conocidos con datos de salida conocida, en búsqueda de mejorar su sistema de procesamiento.

Las ANN han tenido un papel fundamental en distintas áreas de investigación al facilitar la simplificación de tareas, sin embargo, para aprovechar al máximo su uso se requiere el suficiente entrenamiento y una arquitectura adecuada de la ANN (Mukhamediev et al., 2022; García et al., 2024; Zhang, Li, et al., 2023). Cuando se habla de arquitectura se refiere a la organización de la ANN, ya que esto tiene un impacto en el procesamiento de la información (Mukhamediev et al., 2022; García et al., 2024). Los tres tipos de arquitectura básicos de una ANN son: Red neuronal de retroalimentación estándar (Mukhamediev et al., 2022; Zhao et al., 2023); Red neuronal recurrente (RNN, por sus siglas en inglés, *Recurrent Neural Networks*) (Mukhamediev et al., 2022; Zhao et al., 2023); Red neuronal convolucional (CNN, por sus siglas en inglés, *Convolutional Neural Networks*) (Mukhamediev et al., 2022; García et al., 2024; Ihsan et al., 2023; Zhang, Li, et al., 2023). También existen las arquitecturas híbridas que pueden incluir elementos de las arquitecturas básicas (Mukhamediev et al., 2022).

En conclusión, los modelos de ANN pueden analizar distintas fuentes de información (García et al., 2024), ya sea a partir de prompts, o a partir de datos obtenidos por distintas herramientas tecnológicas, por ejemplo, a partir de sensores (Muhammad et al., 2022), biosensores (Kobra Salimiyani rizi & Ashrafi, 2023) o la teledetección (RS, por sus siglas en inglés, *remote sensing*) (Chowdhury et al., 2024; Kobra Salimiyani rizi & Ashrafi, 2023).

3. Minería de datos

La minería de datos, otra herramienta de la IA, se relaciona con un proceso en el que principalmente se requiere descubrir patrones, tendencias, correlaciones y conocimientos dentro de un conjunto de datos (Mukhamediev et al., 2022). Por lo tanto, la minería de datos busca la conversión de datos en información que representa utilidad dependiendo de la finalidad de su uso y esto a su vez, resulta en una toma de decisiones, predicción de tendencias, futuras y la optimización de procesos (Zhao et al., 2023; James et al., 2022).

La minería de datos se basa en una serie de etapas: la extracción de datos, en donde se recopila la información necesaria para el análisis en el cual se implica a la fuente de obtención de datos, luego la exploración de datos en donde se busca su comprensión continua con un modelado y análisis, etapa en la cual se identifican patrones (Mukhamediev et al., 2022) y finalmente validar y evaluar la información y aplicarla en una área específica.

La minería de datos es un campo de aplicación de la IA en donde a partir del ML por medio de sus distintas ramas se puede ejecutar (Ali et al., 2023). Por lo tanto, la minería de datos resulta un área de interés en la investigación, en donde uno de los usos en microbiología es la identificación de microorganismos (Shelke et al., 2023, Zhao et al., 2023; Walsh et al., 2024; Ihsan et al., 2023; Peyman Namadi & Deng, 2023); es así como este ejercicio de la minería de datos es una aplicación importante en el área de la microbiología (Jiang et al., 2022; James et al., 2022). Su gran aporte radica en el uso de mecanismos generales de modelos ML/DL en donde se pueden generar resultados a partir de los datos, que en este caso serían secuencias del genoma completo (Ali et al., 2023; Walsh et al., 2024; Ghannam & Techtmann, 2021; Liang et al., 2020) y análisis en metagenómica (Zhang, Li, et al., 2023) en donde DL/ML predicen eventos a partir de esta información, como por ejemplo resistencia a antimicrobianos (Ali et al., 2023) o la caracterización de comunidades microbianas en un entorno (Ihsan et al., 2023; Jiang et al., 2022; Kobra Salimiyan rizi & Ashrafi, 2023).

4. Internet de las Cosas

El internet de las cosas (IoT, por sus siglas en inglés, *Internet of Things*) en los últimos años ha sido una de las tecnologías más importantes (Ubina et al., 2023), ya que su implementación se realiza desde objetos cotidianos, hasta para procesos más complejos a nivel tecnológico. Este concepto hace relación a la existencia de una interconexión de dispositivos físicos los cuales a su vez están integrados con tecnologías para recopilar y compartir datos por medio del internet, como los sensores (Terence & Geethanjali Purushothaman, 2020).

Existe una relación entre IoT y la IA y se refiere a que la IA se usa para procesar los datos generados por dispositivos IoT, siendo este el principio para automatización de procesos (Ubina et al., 2023; Terence & Geethanjali Purushothaman, 2020). Un ejemplo es su aplicación con el uso de sensores que en el área agroindustrial son fundamentales para múltiples procesos. Es así como los biosensores han tomado relevancia en ese proceso de automatización, algo que no es ajeno al área agroambiental (Ubina et al., 2023; Terence & Geethanjali Purushothaman, 2020); estos se rigen por el principio del IoT y sus datos pueden ser procesados por ANN para simplificar dicha automatización (Muhammad et al., 2022; Kobra Salimiyan rizi & Ashrafi, 2023), lo que también ha sentado las bases de la hoy conocida como agricultura inteligente (Terence & Geethanjali Purushothaman, 2020).

5. Procesamiento del lenguaje natural

Otra herramienta, el procesamiento del lenguaje natural (NLP, por sus siglas en inglés, *Natural Language Processing*) hace parte de la IA que se desarrolla principalmente en la interacción entre el lenguaje humano y la tecnología, es decir, su principal objetivo es permitir la comprensión, interpretación y generación de lenguaje humano (Molik et al., 2021). Por lo cual, tiene implicaciones en la minería de datos y el IoT, ya que aquí se establecen procesos como el reconocimiento del habla, la traducción, extracción de información y el análisis de generación de texto.

6. Bosque Aleatorio

Un bosque aleatorio (RF, por sus siglas en inglés, *Random Forest*) es un algoritmo de ML que generalmente es usado con la finalidad de clasificación y regresión, es una combinación de múltiples modelos de aprendizaje con el fin de mejorar la precisión predictiva (Ricardo Hernández Medina et al., 2022). Se le conoce con el término de bosque, porque se crean distintos tipos de árboles de decisión durante la fase de entrenamiento del ML en donde cada árbol se entrena con una muestra al azar del conjunto de datos que se usa para el ML, es decir, cada árbol es entrenado de forma independiente y cada uno tiene un subconjunto del conjunto de datos de entrenamiento (Ricardo Hernández Medina et al., 2022).

En este sentido, el RF tiene el ideal de diversificar los árboles, de tal manera que se reduce la correlación entre ellos; el conjunto del bosque genera datos nuevos y que no hayan estado previamente. De esta manera, al realizar una predicción con un RF, se combinan las predicciones individuales de cada árbol para llegar a una predicción final (Ricardo Hernández Medina et al., 2022).

7 Máquinas de Vectores de Soporte

Las máquinas de Vectores de Soporte (SVM, por sus siglas en inglés, *Support Vectors Machines*) hace parte de los algoritmos de ML y se basan en el SL, generalmente su uso se enfoca en la clasificación. El principio básico de este algoritmo consiste en funcionar como un clasificador en un hiperplano, en donde separa y clasifica según el lado en el que se encuentre (Hayati et al., 2024).

Inteligencia artificial aplicada a la microbiología agroambiental

De acuerdo con estos conceptos, la IA tiene un impacto en el proceso de digitalización de distintas actividades, dentro de ellas el ejercicio de la microbiología (Ali et al., 2023; Egli et al., 2020; Shelke et al., 2023; Kumar et al., 2023), pero si se habla específicamente de la microbiología agroambiental, la IA se podría concretar en cinco ejes principales (figura 4): 1. Eficiencia en el análisis de datos, 2. Predicción de patrones, 3. Optimización de procesos, 4. Diagnóstico y vigilancia y 5. Modelado y simulación.

Estos componentes se relacionan unos con otros y por ello, la IA facilita el manejo de conjuntos de datos complejos y permite la identificación de patrones en los datos, lo que a su vez impacta en la optimización de procesos, facilita procesos de monitoreo y además simplifica procesos experimentales.




Figura 4. Principales finalidades de la implementación de la IA en la microbiología agroambiental

1. Modelado predictivo de cambios en la biodiversidad microbiana.

El modelado predictivo es una técnica que utiliza datos para predecir eventos futuros, siendo esta una de las aplicaciones más importantes de la IA. Se basa en la construcción de modelos que identifican patrones y relaciones en los datos para hacer proyecciones sobre lo que podría suceder en el futuro, de esta manera los modelos DL/ML son una herramienta de última generación para este proceso de modelado predictivo (Ali et al., 2023).

En este sentido, esta técnica puede ser de utilidad en el análisis de predicción de comunidades microbianas, algo que es fundamental en cualquier estudio de microbiología (Kumar et al., 2023). Un modelo predictivo permite el análisis de datos para caracterizar una comunidad de microorganismos y asociarlos según estas características (Kumar et al., 2023), como por ejemplo aquellos que tengan la capacidad de fijación de nitrógeno, o también aquellos que son solubilizadores de fosfatos (Kumar et al., 2023)

Además, para complementar esa acción de predicción, se pueden incluir más datos, que en el caso de microorganismos ambientales, serían las propiedades del suelo y las condiciones climáticas (Kumar et al., 2023) que van a facilitar la predicción y así determinar la efectividad de diferentes microorganismos en estos ambientes. Estos modelos mejoran la efectividad en la selección de cepas microbianas con distintos fines y a su vez facilitan el desarrollo de nuevas cepas con la finalidad de facilitar su adaptación a un medio específico (Kumar et al., 2023).

2. Metagenómica en el ML

En la metagenómica, se analizan conjuntos de datos masivos para identificar y clasificar la diversidad genética, este campo se enfoca en material genético de distintas muestras lo cual es de importancia en la microbiología ambiental, ya que permite el estudio de muestras ambientales como suelo, agua, lodos, entre otros. Los ensamblajes metagenómicos surgen como una alternativa viable al establecimiento de nuevas especies no cultivables, lo que ha permitido que se conozca la existencia de una diversidad de microbiomas en distintos ambientes (Liang et al., 2020).

La metagenómica hace parte de las ciencias ómicas, las cuales son conocidas por elaborar perfiles rápidos de poblaciones microbianas (James et al., 2022). Los datos que se obtienen a partir de estas ómicas tienen un alto flujo en información, lo que genera un volumen a gran escala de conjuntos de datos, los cuales propiamente tienen un potencial para la clasificación y la predicción ambiental (James et al., 2022). Estos datos traen consigo una complejidad, la cual a su vez oculta los patrones subyacentes a la información biológica, lo cual conlleva una gran problemática para su interpretación manual.

La utilización de algoritmos de IA permite identificar comunidades microbianas en términos de su abundancia y composición, así como constituye el reflejo del ambiente de dicha comunidad (Danijela Šantić et al., 2021; Zou et al., 2024) a partir de la aplicación de distintas ómicas, entre ellas la metagenómica. La ocurrencia de distintas variables ambientales pueden afectar la estructura de estas comunidades microbianas, se ha identificado que el uso de ANN permite generar modelos para predecir los impactos de estas variables en las comunidades relacionando las diversidades microbianas con variables que le dan estructura a esta diversidad (figura 6) (Sun et al., 2020).

Se puede ver como la IA empieza a jugar un papel fundamental en el área de la metagenómica, porque uno de los pasos de mayor importancia en la interpretación de datos metagenómicos es la clasificación taxonómica (Liang et al., 2020). Debido a que el desarrollo de métodos para investigar el papel de estos nuevos organismos no cultivados es de suma importancia para la comprensión de estos microbiomas (Liang et al., 2020), a raíz de que los genomas ensamblados en metagenomas suelen estar muy fragmentados en comparación con los genomas obtenidos mediante la secuenciación del genoma completo a partir de cultivos (Liang et al., 2020), dicha fragmentación dificulta la alineación de manera tradicional, porque estas herramientas sufren una pérdida de rendimiento en presencia de microorganismos desconocidos, razón por la cual estos procesos dependen de un árbol taxonómico recuperado de bases de datos de taxonomía. El DL como parte del ML se establece como una solución por su capacidad de modelado, lo que convierte dicha fragmentación en un problema que no repercute en esta técnica, ya que los genomas se cortan a la longitud de las lecturas de secuenciación que fueron establecidas para el entrenamiento (Liang et al., 2020).

Existe una secuenciación metagenómica que se conoce como “shotgun”, es una técnica usada para muestras ambientales complejas (Ricardo Hernández Medina et al., 2022). A través de diferentes algoritmos de ML, las lecturas metagenómicas de “shotgun” se pueden alinear con bases de datos seleccionadas para realizar anotaciones funcionales o taxonómicas (Ricardo Hernández Medina et al., 2022). El uso del NLP con datos metagenéticos, también es de importancia en esta área por su relación en el análisis de estos datos, ya que al tener esta parte de la IA en conexión con fuentes de datos donde tiene acceso a información de componentes como el ARN ribosómico 18S tiene la capacidad de comprender y analizar diversidades taxonómicas (Molik et al., 2021) basadas en el ML para su procesamiento.

Todos estos avances que se tienen en las distintas ómicas juntos con las técnicas a la vanguardia de secuenciación, han permitido que exista gran cantidad de datos respecto a lo que son los microbiomas y el uso del ML permite el reconocimiento de patrones en este tipo de datos, una

manera de representar estos mismos es por el uso de unidades taxonómicas operacionales (OTU, por sus siglas en inglés, Operational Taxonomic Units) que es de utilidad para categorizar microorganismos siguiendo como principio la similitud de sus secuencias de ADN. Se ha evidenciado que el uso de CNN y RNN para análisis filogenéticos basados en OTUs, ha permitido un mejor análisis de taxones microbianos (Ricardo Hernández Medina et al., 2022), debido a que estas ANN exploran patrones históricos y sus arquitecturas permiten que los estudios de microbiomas generen predicciones temporales y patrones dinámicos generando así los perfiles del microbioma

El ML se posiciona como uno de los modelos adecuados para abordar los desafíos subsecuentes de la metagenómica, de forma tal, que actualmente se están implementando en las ómicas el uso de ML para abordar los distintos desafíos ambientales (James et al., 2022). Dentro de estos desafíos ambientales están los impactos antropogénicos, los cuales están motivando el desarrollo de metodologías de bioevaluación ambiental, entrando así las ómicas y a su vez el ML en el desarrollo de estas actividades del área ambiental (James et al., 2022). Así pues, se reconocen los biosensores, los cuales permiten realizar ese monitoreo de los impactos humanos, los microorganismos son reconocidos por su capacidad de funcionar como dichos biosensores, por lo cual datos de metagenómica de poblaciones microbianas con su respectivo análisis por medio de ML, dan paso a la predicción del impacto y la presencia de contaminantes ambientales (James et al., 2022)

De esta forma, la implementación del ML es un apoyo a los metanálisis ambientales y a la minería de datos, ya que al manejar grandes volúmenes de datos ómicos, el ML simplifica el proceso para proporcionar una mejor visión de las funciones microbianas (James et al., 2022).

3. Herramientas de IA para la monitorización de la calidad del agua y suelo.

La monitorización de la calidad del agua y suelo es un estudio importante que se realiza en la microbiología ambiental, ya que permite establecer la condición de estos ecosistemas a nivel físico, químico y biológico (figura 5). Este monitoreo permite la predicción del deterioro ambiental además de la evaluación de medidas de mitigación de contaminantes, lo que resulta de importancia en la gestión ambiental (Cai et al., 2024).

De esta manera, los microorganismos surgen en la actualidad como bioindicadores del estado ambiental, por lo cual su seguimiento es fundamental en la comprensión del estado ambiental y la implementación del ML basado en ómicas permite realizar este monitoreo (James et al., 2022) y entender la dinámica de estos microorganismos para predecir diferentes impactos ambientales (James et al., 2022).

En cuanto a la monitorización de la calidad del suelo la implementación de herramientas de IA permite el análisis de la calidad del suelo, gracias a la identificación de patrones entre conjuntos de parámetros del suelo (Muhammad Awais et al., 2023), es posible la medición más precisa de dichos parámetros de manera independiente como la textura del suelo o su contenido de agua (Muhammad Awais et al., 2023). Los suelos al representar uno de los recursos naturales más importantes, requiere un adecuado mantenimiento fundamental para el desarrollo agrícola y la sostenibilidad ecológica, debido a que estos proporcionan distintos servicios ecosistémicos esenciales (figura 4) (Wang et al., 2023). Por tal razón, se han podido desarrollar distintos modelos basados principalmente en ML que permite predecir la calidad del suelos y así, actualmente, se están basando en este principio los sistemas agroindustriales. Usar estos modelos permite predecir el rendimiento de cultivos basándose en datos de indicadores químicos, físicos y biológicos del suelo, apoyados de tecnologías como sensores, vehículos aéreos no tripulados o plataformas satelitales que permiten determinar dichos indicadores. (Diaz-Gonzalez et al., 2022)

En cuanto a la monitorización de la calidad del agua, la IA tiene un papel importante (figura 5) en particular cuando se requiere agua potable. En cuanto a la utilización de esta tecnología en sistemas de distribución de agua potable (Soma Safeer et al., 2022; C.H. Pérez-Beltrán et al., 2024; El et al., 2023), el ML ha sido reportado en el procesamiento de datos metagenómicos para modelos predictivos en sistemas de potabilización de agua (Soma Safeer et al., 2022). De esta manera, el ML tiene aplicaciones en este proceso porque permite: modelado de interacciones entre comunidades microbianas (Soma Safeer et al., 2022), predicción de calidad biológica y química del agua (Soma

Safeer et al., 2022), soporte en la toma de decisiones para mantenimiento y operación (Soma Safeer et al., 2022) y optimización de sistema de potabilización (Soma Safeer et al., 2022).

Distintos protocolos de ML permiten por medio de sensores determinar los cambios en cuerpos de agua, los sensores por medio de cambios espectrales con diversos parámetros ambientales y el uso de IA permiten descubrir patrones en los datos del sensor (Staša Puškarić et al., 2024). La capacidad de predicción que tiene el ML puede monitorear así la calidad del agua, e inclusive establecer el origen y las características de una muestra, ya que puede reportar comunidades microbianas a partir de datos que se obtienen de muestras contaminadas con xenobióticos y por datos metagenómicos identificar estas comunidades. Esto resulta también de importancia en salud pública, ya que al usar modelos predictivos de microorganismos como bioindicadores de contaminación pronostica la calidad del agua para la actividad que se tenga destinada, en particular la que se utiliza para el consumo humano (James et al., 2022)

En cuanto a los xenobióticos, en vista de las distintas actividades antropogénicas que generan afectaciones de este ecosistema, las tecnologías de RS son fundamentales para ese proceso de seguimiento de la calidad del agua. Los distintos parámetros que se pueden medir de este ambiente son fundamentales para la monitorización, por lo cual resulta de importancia los datos de RS para su interpretación por medio de algoritmos de IA como SVM, RF, CNN, RNN (Wang et al., 2023).



Figura 5. Imagen generada con IA. Se observa que la monitorización de la calidad de agua y suelo se realiza a partir de parámetros idénticos en ambos casos, dicho monitoreo se hace con la finalidad de evitar la pérdida de usos en cada caso.

Inteligencia artificial aplicada a la agricultura y sanidad de cultivos

La agricultura y el cuidado de los cultivos a lo largo del tiempo se ha visto en constante evolución a la par con el desarrollo tecnológico e industrial y donde el ser humano ha sido protagonista porque ha venido acumulando todos los conocimientos y las prácticas que ofrece la agricultura tradicional. Sin embargo, existen aún problemáticas que conllevan a los distintos desafíos abordados en los tiempos actuales junto a la par de la revolución tecnológica. En este sentido, la agricultura moderna hace frente a las necesidades actuales y al mismo tiempo, aporta e innova, preocupándose por una mayor precisión respecto a las predicciones no solo a nivel de los cambios ambientales sino en las características y propiedades del cultivo. Como estrategia se fomenta el uso de las tecnologías modernas con la finalidad de optimizar la eficacia y productividad sin dejar de lado el nivel de producción, su calidad y el aporte para el cuidado de la sanidad ambiental (Mey et al., 2021; Holzinger et al., 2022; Innocent Kutyauro et al., 2023).

1. Predicción de rendimiento de cultivos mediante IA

Mediante IA es posible identificar el mejor momento para la plantación, permitiendo de esta manera que aumente la productividad, la adaptabilidad y la resistencia, como también, optimizar entre varios aspectos: la economía, el manejo del tiempo y la mano de obra, además de mejorar la sostenibilidad agrícola (Javaid et al., 2023; Huffaker et al., 2024). En el campo de la microbiología y acorde con las poblaciones microbianas y sus curvas de crecimiento es necesario tener en cuenta tres parámetros (el tiempo de retraso, la tasa de crecimiento y el tamaño de la población saturada) junto con los datos relacionados con distintos factores ambientales. Mediante el ML se puede obtener de manera eficaz la dinámica poblacional para poder controlar sus condiciones en un entorno (Aida et al., 2022). De

igual manera, mediante el ML se podrá dar una correcta identificación entre los elementos presentes, detectar impurezas o anomalías que se pueden llegar a presentar en las frutas y verduras, acorde con la medición de su forma, tamaño, color y características biológicas (Javaid et al., 2023; (Vaida Bačiulienė et al., 2023; Jafar et al., 2024; Mana et al., 2024; Chaudhary & Kumar, 2022).

Esta aplicación de algoritmos de ML para los cultivos demuestra ser una herramienta óptima, no solo para obtener información útil respecto a las propiedades de un cultivo en concreto acorde con su análisis morfológico sino que permite predecir y rastrear situaciones ambientales como el cambio climático que puede repercutir en el rendimiento de estos cultivos, mediante el aprendizaje de patrones climáticos históricos (Mey et al., 2021; Javaid et al., 2023; Jafar et al., 2024). En este sentido, mediante el uso de la IA los agricultores pueden llegar a adaptar la gestión agrícola con la finalidad de afrontar los desafíos que puede ofrecer un clima cambiante, incluyéndose en él, la temperatura, la humedad, el clima (Mey et al., 2021; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Jafar et al., 2024; Seyed Mostafa Biazar et al., 2024). Además, estas herramientas podrán ser aplicadas para identificar nuevas variedades de cultivos que sean más eficientes en el uso de recursos y resistentes acorde con las condiciones climáticas variables (Mey et al., 2021; Javaid et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Divyanshu Tirkey et al., 2023).

Mediante técnicas de imagen junto a la ayuda de la IA se puede evaluar la identificación de las plantas con el fin de obtener una evaluación completa de sus características, entre ellas, las imágenes digitales/RGB, RGB-D, termografía, fluorescencia, tomografía computarizada de rayos X, herramientas que proporcionan información sobre el estado fisiológico de las plantas, la presencia de deficiencias nutricionales y un seguimiento preciso de la etapa de desarrollo de las plantas, su morfología, salud y respuesta al estrés (Nabwire et al., 2021; (SHEIKH et al., 2023; Guduru Dhanush et al., 2023; Xaimarie Hernández-Cruz et al., 2023).

Otros métodos como el mapeo de cultivos basado en datos históricos junto al uso de redes neuronales artificiales que superan a los algoritmos de regresión han sido referidos como capaces de la estimación de la tasa de crecimiento del arroz, la combinación de redes neuronales y algoritmos genéticos con los cuales se podrá determinar en forma precisa la edad del cultivo, optimizando así los recursos asignados garantizando una cosecha oportuna (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Mana et al., 2024; Ding et al., 2023). Estas herramientas también permiten el Fenotipado de Alto Rendimiento en Plantas donde la integración de plataformas autónomas y drones en las granjas potenciarán la recopilación de datos espaciales y temporales para un análisis más detallado y preciso (SHEIKH et al., 2023; Abia Katimbo et al., 2023).

A través del IoT cognitivo mediante TCN y RNN se puede impulsar el crecimiento de los cultivos, haciendo uso de pruebas de suelo para el análisis de nutrientes y pH del ambiente en específico, teledetección, análisis de imagen y detección de proximidad, entre otros datos recopilados en distintos dispositivos para mejorar su rendimiento. Además, la CNN se considera que es uno de los algoritmos más confiables para estimar el rendimiento de los cultivos (Bhardwaj et al., 2022; Javaid et al., 2023; Seyed Mostafa Biazar et al., 2024; Mana et al., 2024). Por otra parte se han identificado nanoagroquímicos, que incluyen los nanopesticidas y nanofertilizantes que son productos que utiliza la nanotecnología para mejorar la eficiencia y sostenibilidad en la agricultura (Wahab et al., 2024; Ahmed et al., 2023).

2. Diagnóstico automatizado de enfermedades en plantas.

Se han visto desarrollos de aplicaciones móviles inteligentes para diagnosticar enfermedades del trigo con una precisión que ronda hasta el 99% (Innocent Kutyauro et al., 2023), como también el uso de sistemas de IA para identificar la gravedad de enfermedades en cultivos como la pimienta. Por otra parte, se utilizan vehículos aéreos no tripulados vinculados a la nube y algoritmos de IA para detectar plagas en el arroz (Innocent Kutyauro et al., 2023).

En lo relacionado con la identificación, habrá modelos de detección que podrán aprender de grandes conjuntos de datos etiquetados para identificar patrones y características asociadas con enfermedades específicas. Adicionalmente, combinando algoritmos de alto rendimiento con IA, se logra analizar imágenes o datos de sensores para detectar signos tempranos de enfermedades,

permitiendo intervenciones precisas y oportunas (SHEIKH et al., 2023; Vaida Bačiulienė et al., 2023; Jafar et al., 2024).

El uso de biosensores basados en IA puede actuar inclusive en plantas que se podrían considerar asintomáticas, ayudando a que se minimice la pérdida de cultivo basada en estresores bióticos (Bhardwaj et al., 2022). De igual manera, en el contexto de las tecnologías, se encuentran drones basados en IA como EfficientNetV2, ofreciendo una precisión mayor al 99% en la detección de enfermedades de plantas; también hay un modelo de IA híbrido, utilizando autocodificador convolucional y CNN, para la detección de enfermedades bacterianas (Bhardwaj et al., 2022).

Respecto a la IA se han utilizado diferentes modelos como ML, ANN, SVM, Red de Memoria a Corto Plazo (LSTM, por sus siglas en inglés, *Long short-term memory network*), Regresión logística (LR, por sus siglas en inglés, *Logistic regression*), KNN, RF, Clasificación de Máquina Vectorial de Soporte (SVC, por sus siglas en inglés, *Support Vector Machine Classification*), ANN, Función de Base Radial (RBF, por sus siglas en inglés, *Radial Basis Function*), Aprendizaje de Cuantificación Vectorial (LVQ, por sus siglas en inglés, *Learning Vector Quantization*), Perceptrón multicapa (MLP, por sus siglas en inglés, *Multi-layer Perceptron*), los cuales mediante ciertos parámetros meteorológicos históricos brinda datos con los cuales se pueden hacer predicciones ambientales (Gianni Fenu & Francesca Maridina Mallocci, 2021).

3. Aplicaciones de IA en el control de plagas y enfermedades agrícolas

La visión artificial (MV) se ha empleado para desarrollar un sistema inteligente de pulverización que rocía con precisión las malezas sobre cultivos como la pimienta y plantas artificiales, evitando daños a otras plantas no deseadas. Estas tecnologías logran asegurar el uso efectivo de agroquímicos, reduciendo las lesiones en los cultivos y minimizando el desperdicio de estos productos (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Marios Vasileiou et al., 2024). Mediante la IA, es posible el reconocimiento de imágenes, obteniendo algoritmos los cuales, mediante una aplicación, además de identificar y erradicar malezas, hacen una precisa diferenciación entre lo que es un cultivo y una maleza. Es posible, además, detectar y pronosticar de manera temprana enfermedades de plantas y recomendar la medida más eficiente y óptima para brindar un adecuado control de insectos plagas y evidenciar sus ataques inminentes (Javaid et al., 2023; Marios Vasileiou et al., 2024; Vaida Bačiulienė et al., 2023; Jonak et al., 2024).

Por otra parte, el ML permite a los agricultores dar una identificación de las posibles artrópodos plaga y enfermedades que puedan repercutir en el sistema de raíces de la plantación específica en el cultivo (Javaid et al., 2023). Otros modelos, como Big Data, además de la IA y el ML permitirán detectar en tiempo real enfermedades y diferentes plagas, a través de imágenes satelitales (Javaid et al., 2023; Marios Vasileiou et al., 2024). Otros algoritmos avanzados de IA como el Fuzzy Logic, brindará una evaluación detallada y gradual de los datos, especialmente en casos donde las variables no se ajustan fácilmente a categorías binarias, como la presencia de plagas o las condiciones ambientales, esto junto a la ML tienen mucho potencial en la gestión de plagas (Komi Mensah Agboka et al., 2024).

4. Robótica agrícola basada en IA para tareas de cultivo y cosecha.

La robótica agrícola IA está revolucionando las tareas de cultivo y cosecha en la agricultura moderna usando distintos algoritmos como las SVM, los RF, el Vecino más Cercano (KNN, por sus siglas en inglés, *K-nearest neighbors*) y el Refuerzo Adaptativo con la finalidad de predecir la evapotranspiración de cultivos como la remolacha azucarera en regiones semiáridas, siendo el método SVM el más efectivo. Además, la integración del IoT (Vaida Bačiulienė et al., 2023) en sistemas de riego con agentes multi inteligentes y ciber físicos mejoran la eficiencia del uso del agua, permitiendo un suministro más preciso y controlado. La combinación de agentes robóticos y software de monitoreo en el campo optimizarán las operaciones agrícolas, mejorando así la productividad y la sostenibilidad en la agricultura (Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Divyanshu Tirkey et al., 2023).

Diversas tecnologías y algoritmos de IA junto con el uso de drones han sido empleados para diversas tareas; mediante las características geográficas del sitio en concreto y distintos criterios que lo componen, puede ayudar a los agricultores a mantener la sostenibilidad e integridad del suelo

mediante una variedad de indicadores biológicos, elegir lugares apropiados para plantar, así como la aplicación de pesticidas. Este monitoreo tiene como finalidad evaluar la salud y el mapeo de cultivos para lograr condiciones óptimas. La IA ha llegado a ser aplicada en robots autónomos de deshierba, utilizando láser de alta potencia mediante el uso de descargas eléctricas (Innocent Kutyauro et al., 2023; Javaid et al., 2023; Vaida Bačiulienė et al., 2023; Xaimarie Hernández-Cruz et al., 2023; Huffaker et al., 2024).

Otras herramientas sistemas de visión artificial como las cámaras de seguridad se usan con el fin de detectar y localizar frutos o cultivos para su seguimiento, además de reconocer tanto animales, humanos u cualquier invasor que pueda llegar a dañar los cultivos. Es un sistema que mediante una computadora analiza imágenes estáticas y en movimiento, proporcionando datos como la nube de puntos 3D, además de la posición de los cultivos o la fruta para cosechar y empacar (Guduru Dhanush et al., 2023; Javaid et al., 2023; Marios Vasileiou et al., 2024; Huffaker et al., 2024).

5. Optimización de sistemas de riego mediante algoritmos de IA.

La optimización de sistemas de riego mediante algoritmos de IA brinda un avance importante en la gestión agrícola pues permite analizar datos en tiempo real, como información sobre el suelo, el clima y las necesidades hídricas de los cultivos (Innocent Kutyauro et al., 2023), para tomar decisiones precisas (Innocent Kutyauro et al., 2023; Mana et al., 2024) y eficientes en cuanto a la cantidad y el momento adecuados para aplicar el riego. Además, cuando se integra la IA en los sistemas de riego (Innocent Kutyauro et al., 2023), se observa una gestión más inteligente y automatizada del agua, lo que permite maximizar el rendimiento de los cultivos y contribuye a la conservación de este recurso vital y a la sostenibilidad de la agricultura (Innocent Kutyauro et al., 2023; Vaida Bačiulienė et al., 2023; Mana et al., 2024).

Mediante estas herramientas se facilita la labor y se logra la economía por el acceso sencillo a la información, archivos y datos recolectados mediante la IA gracias a hardware especializado como las fotos satelitales, IoT, se ha podido optimizar para la mejor toma de decisiones en el riego de las plantas (Holzinger et al., 2023). Además, según el IoT junto a ciertos implementos como controladores, actuadores, sensores, módulos de comunicación, aplicaciones de dispositivos móviles y tecnología en la nube, entre otros, se puede llegar a implementar un sistema de riego inteligente y remoto (Mana et al., 2024).

Con la finalidad de aprovechar bien el recurso agua, se puede generar un análisis de datos en los patrones de riego que den un buen uso de este recurso natural, disminuya el riesgo de escasez y favorezca al ambiente (Javaid et al., 2023). De igual manera, y para dar un riego eficiente y efectivo, además de poder medirse en este suelo la humedad y los requisitos fundamentales para incorporarse en los cultivos se han llegado a dar innovaciones en la tecnología de la IA con la lógica difusa, los algoritmos metaheurísticos y las redes neuronales artificiales (Bhardwaj et al., 2022; Mana et al., 2024).

Inteligencia artificial en procesos de biorremediación

1. Modelado de la degradación de contaminantes con IA.

En el contexto de la contaminación por hidrocarburos, el uso de IA, como ANN, SVM y los ANFIS tiene gran relevancia debido a que estas herramientas avanzadas de modelado permiten predecir y optimizar los procesos de degradación de contaminantes; a través de ese monitoreo se pueden tomar medidas para remediar la calidad ambiental, optimizar condiciones de crecimiento para la degradación de hidrocarburos, identificar fuentes de contaminación en cuerpos de agua, y predecir propiedades reológicas de derivados del petróleo brindando de esta manera una mejor comprensión respecto a la complejidad de los procesos de biorremediación. Por otra parte, se puede hacer una prevención con cierto nivel de precisión sobre las condiciones óptimas para la degradación y eliminación eficiente de los hidrocarburos (Salgado et al., 2023; Matthew Ndubuisi Abonyi et al., 2023; Rupshikha Patowary et al., 2023; Dmitrii Shadrin et al., 2020).

Otras herramientas complementarias como la simulación de Monte Carlo (MCS, por sus siglas en inglés, *Monte Carlo simulation*), los Algoritmos Inmunes Artificiales (AIS, por sus siglas en inglés,

Artificial Immune Systems), los Árboles de regresión Potenciados (BRT, por sus siglas en inglés, *Boosted Regression Tree*) y los Algoritmos de Colonia de Hormigas (ACA, por sus siglas en inglés, *Ant Colony Algorithm*), además de RSM junto con algoritmos como la propagación posterior Levenberg-Marquardt, el algoritmo Otsu y el Algoritmo de Región Extrema Máximamente Estable (MSERA, por sus siglas en inglés, *Maximally Stable Extremal Region Algorithm*), ayudan en diversas tareas, incluida la simulación de procesos de degradación y la detección automática de derrames de petróleo. Estos enfoques mejoran la eficiencia y precisión de los procesos de restauración ambiental (Rupshikha Patowary et al., 2023; Dmitrii Shadrin et al., 2020).

Las tecnologías de imágenes microplásticas basadas en IA son una herramienta importante y con potencial en el modelado de la degradación de contaminantes, especialmente en los ecosistemas marinos, permitiendo la identificación y cuantificación precisa de este contaminante. Además, estas tecnologías están transformando la investigación tradicional sobre este tipo de contaminación, mejorando la eficiencia operativa y facilitando una comprensión más completa de este problema ambiental (Zhang, Zhang, et al., 2023).

2. Diseño asistido por IA de microorganismos modificados para la biorremediación.

Algunos microorganismos o sus productos cuando se modifican tienen la capacidad para biorremediar. Es el caso de la fucoxantina carotenoide presente en diversas microalgas, como las algas pardas y las diatomeas, la cual contribuyen en la biorremediación al mejorar la capacidad de los microorganismos para degradar contaminantes en aguas y suelos polucionados con metales pesados y compuestos orgánicos tóxicos (Roy et al., 2023). En este sentido, para optimizar la extracción y uso de fucoxantina en estos procesos, gracias a la IA se pueden utilizar diferentes modelos como la Metodología de Superficie de Respuesta (RSM, por sus siglas en inglés, *Response Surface Methodology*), ANN, Algoritmos Genéticos (GA, por sus siglas en inglés, *Genetic Algorithm*) y el Sistema de Inferencia Neuro-Fuzzy Adaptativo (ANFIS, por sus siglas en inglés, *Adaptive Neuro Fuzzy Inference System*), los cuales aumentan el rendimiento de extracción, permitiendo de esta manera reducir costos y mejorar la eficiencia del proceso, facilitando así su aplicación en la biorremediación (Roy et al., 2023).

Finalmente, mediante ANN para la optimización de la producción de una enzima fúngica denominada lipasa, es posible hacer más eficiente la producción de biodiesel mediante desechos aceitosos de origen agrícola y alimentario, logrando una mejor producción de Diesel con mejor eficiencia y a menores costos (El-Metwally et al., 2023).

3. Control automatizado de procesos de tratamiento de aguas residuales.

Las microalgas son organismos altamente eficientes en términos de crecimiento y fotosíntesis, lo que las hace valiosas para diversas aplicaciones, siendo las más importante, el tratamiento de aguas residuales, esto debido a su capacidad para eliminar eficientemente los contaminantes, al mismo tiempo que crecen de manera acelerada gracias al nitrógeno y fósforo que se encuentran en este medio. Sin embargo, el tratamiento tradicional de estas aguas residuales presenta limitaciones, que podría mejorarse empleando ciertos modelos, como ANN, para predecir y optimizar variables de proceso junto con GA, para brindar una mejor comprensión de los nutrientes que afectan el crecimiento de estas microalgas y cómo eliminan estos contaminantes para determinar las variables clave del proceso, su impacto en la productividad de la biomasa y la eliminación de nutrientes contribuyendo significativamente en la eficiencia y sostenibilidad de los sistemas de tratamiento de aguas residuales basados en microalgas (Salgado et al., 2023).

4. Simulación de escenarios de biorremediación con técnicas de IA.

Gracias a la integración de tres tecnologías, IA, ML y DL se pueden analizar extensos conjuntos de datos brindando una mejora en la comprensión de la contaminación, reduciendo la necesidad de muestreo y los costos en las pruebas de laboratorio, optimizando de esta manera la selección de técnicas de remediación. Los resultados mejoran notablemente y se logra de esta manera una limpieza más efectiva y eficiente, minimizando los riesgos para la salud humana y los ecosistemas (Jagadeesh Kumar Janga et al., 2023).

En lo referente a contaminación con plomo y zinc en suelos, la IA va a mejorar significativamente el control de la contaminación, utilizando varios enfoques: Modelado Predictivo de la IA que analiza factores geológicos, mineros y climáticos para identificar zonas de alto riesgo, facilitando una asignación eficiente de recursos, uso de sensores y drones impulsados por IA que permiten monitorear la calidad del suelo en tiempo real y detectar tempranamente la contaminación y la optimización de los esfuerzos de remediación, lo cual se logra mediante algoritmos que analizan datos del suelo y determinan las estrategias más eficaces. Se observa, entonces como la IA proporciona soluciones costo-efectivas al enfocar recursos en áreas críticas, ahorrando además materia prima (Atoosa Haghighizadeh et al., 2024; El-Metwally et al., 2023).

Inteligencia artificial en la sostenibilidad ambiental

Mediante el uso de la IA se busca mejorar los sistemas de gestión de recursos y la mitigación de efectos ambientales, debido a que estos impactos ambientales pueden tener un efecto en las distintas poblaciones biológicas incluidos los microbiomas. El manejo de gran cantidad de datos ambientales permite a través de la IA una toma de decisiones en pro de reducir distintas fuentes de impactos ambientales.

1. Análisis de impactos ambientales con modelos de IA.

La IA tiene un enorme impacto en el monitoreo y pronósticos en las ciencias de la tierra, ayudando a enfrentar problemáticas ambientales recientes (Sun et al., 2022). Se aplica en la atmósfera, geosfera, hidrología, criosfera, oceanografía y biosfera, facilitando el monitoreo a corto y largo plazo y la identificación de perturbaciones naturales y humanas (Figura 6) (Chowdhury et al., 2024). La IA analiza aspectos como condiciones climáticas, perturbaciones del ecosistema, calidad de aire, agua y suelo, actividades geológicas y principios de vida en la tierra (Sun et al., 2022), optimizando procesos y generando datos para comprender impactos ambientales y resolver problemas importantes (Sun et al., 2022). En cuanto a la contaminación del agua, la IA mejora el monitoreo y la toma de decisiones para el tratamiento del agua, analizando su impacto en la salud pública y ecosistemas (Staša Puškarić et al., 2024; Emmanuel Kwame Nti et al., 2023; El et al., 2023). Esto se relaciona directamente con los Objetivos de Desarrollo Sostenible de la ONU sobre agua potable y saneamiento (Emmanuel Kwame Nti et al., 2023).




Figura 6. Imágenes obtenidas con IA. Se representa la aplicabilidad para el análisis de impactos ambientales desde las ciencias de la tierra.

2. Optimización de la gestión de residuos mediante algoritmos de IA.

La gestión adecuada de residuos es clave para el desarrollo sostenible, tiene un impacto importante ya que de aquí surgen los xenobióticos que tienen efectos negativos ambientales y que representa en términos microbianos afectaciones en la composición de una comunidad microbiana. La IA optimiza este proceso determinando el destino final más adecuado de los residuos según diversos modelos de ML. Adicionalmente, facilita la conversión de residuos en energía y su clasificación para distintos fines, mejorando los planes de gestión y alineándose con los objetivos de desarrollo sostenible, especialmente en reciclaje (Fang et al., 2023).

En las "ciudades inteligentes", la gestión de residuos fomenta una "economía circular sin residuos" centrada en el reciclaje, la reutilización y el tratamiento adecuado de los residuos. La IA considera factores geográficos, tasas de generación de residuos, instalaciones, transporte y costos, mejora la toma de decisiones, posicionándola como una tecnología viable para la gestión de residuos (Fang et al., 2023).

Conclusiones y Perspectivas a futuro

La inteligencia artificial (IA) está transformando las ciencias agroambientales, especialmente la microbiología ambiental, con un potencial significativo para optimizar diversos procesos. Aunque todavía en fase de implementación, su llegada es inminente y promete mejoras en la precisión de análisis ambientales, sistemas productivos de cultivos, y la gestión sostenible de recursos naturales.

La IA se destaca por su capacidad para analizar grandes volúmenes de datos y generar patrones útiles, facilitando decisiones más acertadas en laboratorios de microbiología, cultivos y eco ciudades. En el futuro, la integración de IA con IoT, robótica, sensores y drones ampliará aún más sus aplicaciones en el campo agroambiental, respondiendo a nuevas necesidades y mejorando procesos.

El desarrollo de algoritmos más sofisticados y una creciente disponibilidad de datos ambientales impulsarán avances en microbiología y áreas afines. Para aprovechar plenamente estas tecnologías, científicos, ingenieros, agricultores y formuladores de políticas deben actualizarse constantemente. Con un enfoque multidisciplinario, la IA tiene el potencial de contribuir significativamente a la sostenibilidad ambiental, siempre considerando los aspectos éticos y sociales para asegurar soluciones inclusivas.

Referencias:

- Abia Katimbo, Rudnick, D. R., Zhang, J., Ge, Y., DeJonge, K. C., Franz, T. E., Shi, Y., Liang, W., Qiao, X., Heeren, D. M., Kabenge, I., Hope Njuki Nakabuye, & Duan, J. (2023). Evaluation of artificial intelligence algorithms with sensor data assimilation in estimating crop evapotranspiration and crop water stress index for irrigation water management. *Smart Agricultural Technology*, 4, 100176. <https://doi.org/10.1016/j.atech.2023.100176>
- Ahmed, A., He, P., He, P., Wu, Y., He, Y., & Munir, S. (2023). Environmental effect of agriculture-related manufactured nano-objects on soil microbial communities. *Environment International*, 173, 107819. <https://doi.org/10.1016/j.envint.2023.107819>
- Aida, H., Hashizume, T., Kazuha Ashino, & Ying, B.-W. (2022). Machine learning-assisted discovery of growth decision elements by relating bacterial population dynamics to environmental diversity. *ELife*, 11. <https://doi.org/10.7554/eLife.76846>
- Ali, T., Ahmed, S., & Aslam, M. (2023). Artificial intelligence for antimicrobial resistance prediction: Challenges and opportunities towards practical implementation. *Antibiotics (Basel, Switzerland)*, 12(3). <https://doi.org/10.3390/antibiotics12030523>
- Asala Mahajna, Dinkla, I. J. T., Euverink, J. W., Keesman, K. J., & Bayu Jayawardhana. (2022). Clean and safe drinking water systems via metagenomics data and artificial intelligence: State-of-the-art and future perspective. *Frontiers in Microbiology*, 13, 832452. <https://doi.org/10.3389/fmicb.2022.832452>
- Atoosa Haghhighizadeh, Rajabi, O., Arman Nezarat, Zahra Hajyani, Haghmohammadi, M., Soheila Hedayatikhah, Soheila Delnabi Asl, & Ali Aghababai Beni. (2024). Comprehensive analysis of heavy metal soil contamination in mining Environments: Impacts, monitoring Techniques, and remediation strategies. *Arabian Journal of Chemistry*, 17(6), 105777. <https://doi.org/10.1016/j.arabjc.2024.105777>
- Bhardwaj, A., Kishore, S., & Pandey, D. K. (2022). Artificial intelligence in biological sciences. *Life (Basel, Switzerland)*, 12(9). <https://doi.org/10.3390/life12091430>
- C.H. Pérez-Beltrán, Robles, A. D., Rodriguez, N. A., F. Ortega-Gavilán, & A.M. Jiménez-Carvelo. (2024). Artificial intelligence and water quality: From drinking water to wastewater. *TrAC Trends in Analytical Chemistry*, 172, 117597. <https://doi.org/10.1016/j.trac.2024.117597>
- Cai, D., Aziz, G., Sarwar, S., Majid Ibrahim Alsaggaf, & Sinha, A. (2024). Applicability of denoising-based artificial intelligence to forecast the environmental externalities. *Geoscience Frontiers*, 15(3), 101740. <https://doi.org/10.1016/j.gsf.2023.101740>
- Chaudhary, B., & Kumar, V. (2022). Emerging technological frameworks for the sustainable agriculture and environmental management. *Sustainable Horizons*, 3, 100026. <https://doi.org/10.1016/j.horiz.2022.100026>
- Chowdhury, M., Alejo Martínez-Sansigre, Mole, M., Alonso-Peleato, E., Nadiia Basos, Jose Manuel Blanco, Ramirez-Nicolas, M., Caballero, I., & Ignacio. (2024). AI-driven remote sensing enhances Mediterranean seagrass monitoring and conservation to combat climate change and anthropogenic impacts. *Scientific Reports*, 14(1), 8360. <https://doi.org/10.1038/s41598-024-59091-7>
- Chu, E. W., & Karr, J. R. (2017). Environmental impact: Concept, consequences, measurement ☆. In *Reference Module in Life Sciences*. Elsevier. <https://doi.org/10.1016/B978-0-12-809633-8.02380-3>
- Danijela Šantić, Kasia Piwosz, Frano Matic, Ana Vrdoljak Tomaš, Jasna Arapov, Jason Lawrence Dean, Mladen Šolić, Koblížek, M., Grozdan Kušpilić, & Stefanija Šestanović. (2021). Artificial neural network analysis of microbial diversity in the central and southern Adriatic Sea. *Scientific Reports*, 11(1), 11186. <https://doi.org/10.1038/s41598-021-90863-7>
- Diaz-Gonzalez, F. A., Vuelvas, J., Correa, C. A., Vallejo, V. E., & Patino, D. (2022). Machine learning and remote sensing techniques applied to estimate soil indicators – Review. *Ecological Indicators*, 135, 108517. <https://doi.org/10.1016/j.ecolind.2021.108517>
- Ding, H., Tian, J., Yu, W., Wilson, D. I., Young, B. R., Cui, X., Xin, X., Wang, Z., & Li, W. (2023). The application of artificial intelligence and big data in the food industry. *Foods (Basel, Switzerland)*, 12(24). <https://doi.org/10.3390/foods12244511>
- Divyanshu Tirkey, Kshitiz Kumar Singh, & Tripathi, S. (2023). Performance analysis of AI-based solutions for crop disease identification, detection, and classification. *Smart Agricultural Technology*, 5, 100238. <https://doi.org/10.1016/j.atech.2023.100238>
- Dmitrii Shadrin, Mariia Pukalchik, Ekaterina Kovaleva, & Fedorov, M. (2020). Artificial intelligence models to predict acute phytotoxicity in petroleum contaminated soils. *Ecotoxicology and Environmental Safety*, 194, 110410. <https://doi.org/10.1016/j.ecoenv.2020.110410>

- Egli, A., J Schrenzel, & G Greub. (2020). Digital microbiology. *Clinical Microbiology and Infection : The Official Publication of the European Society of Clinical Microbiology and Infectious Diseases*, 26(10), 1324–1331. <https://doi.org/10.1016/j.cmi.2020.06.023>
- El, A., Mandi, L., Aya Kammoun, Naaila Ouazzani, Monga, O., & Moulay Lhassan Hbid. (2023). Artificial intelligence and wastewater treatment: A global scientific perspective through text mining. *Water*, 15(19), 3487. <https://doi.org/10.3390/w15193487>
- El-Metwally, M. M., Abdel-Fattah, G. M., Al-Otibi, F. O., Dina K.H.EL. Khatieb, Helmy, Y. A., Mohammed, Y. M. M., & Saber, W. I. A. (2023). Application of artificial neural networks for enhancing *Aspergillus flavipes* lipase synthesis for green biodiesel production. *Heliyon*, 9(9), e20063. <https://doi.org/10.1016/j.heliyon.2023.e20063>
- Emmanuel Kwame Nti, Samuel Jerry Cobbina, Eunice Efua Attafuah, Lydia Dziedzorm Senanu, Amenyeku, G., Michael Amoah Gyan, Forson, D., & Safo, A.-R. (2023). Water pollution control and revitalization using advanced technologies: Uncovering artificial intelligence options towards environmental health protection, sustainability and water security. *Heliyon*, 9(7), e18170. <https://doi.org/10.1016/j.heliyon.2023.e18170>
- Fang, B., Yu, J., Chen, Z., Osman, A. I., Farghali, M., Ihara, I., Hamza, E. H., Rooney, D. W., & Yap, P.-S. (2023). Artificial intelligence for waste management in smart cities: a review. *Environmental Chemistry Letters*, 1–31. <https://doi.org/10.1007/s10311-023-01604-3>
- Francisco Castillo Díaz. (2022). Cinco aplicaciones de la inteligencia artificial en agricultura. In *Plataforma Tierra*.
- Ghannam, R. B., & Techtmann, S. M. (2021). Machine learning applications in microbial ecology, human microbiome studies, and environmental monitoring. *Computational and Structural Biotechnology Journal*, 19, 1092–1107. <https://doi.org/10.1016/j.csbj.2021.01.028>
- Gianni Fenu, & Francesca Maridina Mallocci. (2021). Forecasting plant and crop disease: An explorative study on current algorithms. *Big Data and Cognitive Computing*, 5(1), 2. <https://doi.org/10.3390/bdcc5010002>
- Goodswen, S. J., Barratt, J. L. N., Kennedy, P. J., Kaufer, A., Calarco, L., & Ellis, J. T. (2021). Machine learning and applications in microbiology. *FEMS Microbiology Reviews*, 45(5). <https://doi.org/10.1093/femsre/fuab015>
- Guduru Dhanush, Khatri, N., Kumar, S., & Praveen Kumar Shukla. (2023). A comprehensive review of machine vision systems and artificial intelligence algorithms for the detection and harvesting of agricultural produce. *Scientific African*, 21, e01798. <https://doi.org/10.1016/j.sciaf.2023.e01798>
- Gupta, A., Gupta, R., & Ram Lakhan Singh. (2017). Microbes and environment. In *Principles and Applications of Environmental Biotechnology for a Sustainable Future* (pp. 43–84). Springer Singapore. https://doi.org/10.1007/978-981-10-1866-4_3
- Hayati, R., Agus Arip Munawar, Endang Lukitaningsih, Nanda Earlia, Taufiq Karma, & Rinaldi Idroes. (2024). Combination of PCA with LDA and SVM classifiers: A model for determining the geographical origin of coconut in the coastal plantation, Aceh Province, Indonesia. *Case Studies in Chemical and Environmental Engineering*, 9, 100552. <https://doi.org/10.1016/j.cscee.2023.100552>
- Holzinger, A., Keiblinger, K., Holub, P., Zatloukal, K., & Heimo Müller. (2023). AI for life: Trends in artificial intelligence for biotechnology. *New Biotechnology*, 74, 16–24. <https://doi.org/10.1016/j.nbt.2023.02.001>
- Holzinger, A., Saranti, A., Alessa Angerschmid, Carl Orge Retzlaff, Gronauer, A., Vladimir Pejakovic, Medel-Jimenez, F., Krexner, T., Gollob, C., & Stampfer, K. (2022). Digital transformation in smart farm and forest operations needs human-centered AI: Challenges and future directions. *Sensors*, 22(8), 3043. <https://doi.org/10.3390/s22083043>
- Huffaker, R., Muñoz-Carpena, R., & Migliaccio, K. W. (2024). Sensor records can be used to forecast complex soil moisture dynamics with symbiosis of empirical nonlinear dynamics and echo state neural network AI. *Computers and Electronics in Agriculture*, 222, 109031. <https://doi.org/10.1016/j.compag.2024.109031>
- Ihsan, A., Khairul Muttaqin, Rahmatul Fajri, Mursyidah Mursyidah, & Islam. (2023). Innovative bacterial colony detection: Leveraging multi-feature selection with the improved salp swarm algorithm. *Journal of Imaging*, 9(12), 263. <https://doi.org/10.3390/jimaging9120263>
- Innocent Kutyauro, Munyaradzi Rushambwa, & Lyndah Chiwazi. (2023). Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 11, 100502. <https://doi.org/10.1016/j.jafr.2023.100502>
- Jafar, A., Bibi, N., Rizwan Ali Naqvi, Abolghasem Sadeghi-Niaraki, & Jeong, D. (2024). Revolutionizing agriculture with artificial intelligence: plant disease detection methods,

- applications, and their limitations. *Frontiers in Plant Science*, 15, 1356260. <https://doi.org/10.3389/fpls.2024.1356260>
- Jagadeesh Kumar Janga, Reddy, K. R., & K.V.N.S. Raviteja. (2023). Integrating artificial intelligence, machine learning, and deep learning approaches into remediation of contaminated sites: A review. *Chemosphere*, 345, 140476. <https://doi.org/10.1016/j.chemosphere.2023.140476>
- James, Mary Krystelle Catacutan, Aurelie Mawart, Hasan, A., & Dias, J. (2022). Interfacing machine learning and microbial omics: A promising means to address environmental challenges. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.851450>
- Javaid, M., Haleem, A., Ibrahim Haleem Khan, & Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15–30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Jiang, Y., Luo, J., Huang, D., Liu, Y., & Li, D. (2022). Machine learning advances in microbiology: A review of methods and applications. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.925454>
- Jonak, M., Mucha, J., Jezek, S., Kovac, D., & Kornel Cziria. (2024). SPAGRI-AI: Smart precision agriculture dataset of aerial images at different heights for crop and weed detection using super-resolution. *Agricultural Systems*, 216, 103876. <https://doi.org/10.1016/j.agry.2024.103876>
- Kapur, R. (2019). *Environmental microbiology and components of the environment*.
- Kobra Salimiyan rizi, & Ashrafi, A. (2023). Biosensors, mechatronics, & microfluidics for early detection & monitoring of microbial corrosion: A comprehensive critical review. *Results in Materials*, 18, 100402. <https://doi.org/10.1016/j.rinma.2023.100402>
- Komi Mensah Agboka, Henri, Abdel-Rahman, E. M., Odindi, J., Onesimo Mutanga, & Saliou Niassy. (2024). Leveraging computational intelligence to identify and map suitable sites for scaling up augmentative biological control of cereal crop pests. *Biological Control*, 190, 105459. <https://doi.org/10.1016/j.biocontrol.2024.105459>
- Krenn, M., Pollice, R., Si Yue Guo, Matteo Aldeghi, Cervera-Lierta, A., Friederich, P., Gabriel, Florian Häse, Jinich, A., Nigam, A., Yao, Z., & Alán Aspuru-Guzik. (2022). On scientific understanding with artificial intelligence. *Nature Reviews Physics*, 4(12), 761–769. <https://doi.org/10.1038/s42254-022-00518-3>
- Kumar, R., Yadav, G., Kuddus, M., Ghulam Md Ashraf, & Singh, R. (2023). Unlocking the microbial studies through computational approaches: how far have we reached? *Environmental Science and Pollution Research*, 30(17), 48929–48947. <https://doi.org/10.1007/s11356-023-26220-0>
- Liang, Q., Bible, P. W., Liu, Y., Zou, B., & Wei, L. (2020). DeepMicrobes: taxonomic classification for metagenomics with deep learning. *NAR Genomics and Bioinformatics*, 2(1). <https://doi.org/10.1093/nargab/lqaa009>
- Lu, Y., Lu, X., Zheng, L., Sun, M., Chen, S., Chen, B., Wang, T., Yang, J., & Chunli Lv. (2024). Application of multimodal transformer model in intelligent agricultural disease detection and question-answering systems. *Plants*, 13(7), 972. <https://doi.org/10.3390/plants13070972>
- Mana, A. A., A. Allouhi, A. Hamrani, Rehman, S., I. el Jamaoui, & K. Jayachandran. (2024). Sustainable AI-based production agriculture: Exploring AI applications and implications in agricultural practices. *Smart Agricultural Technology*, 7, 100416. <https://doi.org/10.1016/j.atech.2024.100416>
- Marios Vasileiou, Leonidas Sotirios Kyrgiakos, Kleisiari, C., Georgios Kleftodimos, Vlontzos, G., Hatem Belhouchette, & Pardalos, P. M. (2024). Transforming weed management in sustainable agriculture with artificial intelligence: A systematic literature review towards weed identification and deep learning. *Crop Protection*, 176, 106522. <https://doi.org/10.1016/j.cropro.2023.106522>
- Matthew Ndubuisi Abonyi, Joseph Tagbo Nwabanne, Paschal Enyinnaya Ohale, Emmanuel Chinagorom Nwadike, Igbonekwu, L. I., Monday Morgan Chukwu, & Emeka Michael Madiebo. (2023). Application of RSM and ANFIS in the optimal parameter evaluation for crude oil degradation in contaminated water amended with PES. *Case Studies in Chemical and Environmental Engineering*, 8, 100483. <https://doi.org/10.1016/j.cscee.2023.100483>
- Mey, F., Clauwaert, J., Kirsten Van Huffel, Willem Waegeman, & Marjan De Mey. (2021). Improving the performance of machine learning models for biotechnology: The quest for deus ex machina. *Biotechnology Advances*, 53, 107858. <https://doi.org/10.1016/j.biotechadv.2021.107858>
- Miller, T., Grzegorz Mikiciuk, Kisiel, A., Małgorzata Mikiciuk, Paliwoda, D., Sas-Paszt, L., Cembrowska-Lech, D., Krzemińska, A., Agnieszka Kozioł, & Brysiewicz, A. (2023). Machine

- learning approaches for forecasting the best microbial strains to alleviate drought impact in agriculture. *Agriculture*, 13(8), 1622. <https://doi.org/10.3390/agriculture13081622>
- Molik, D. C., Tomlinson, D., Davitt, S., Morgan, E. L., Sisk, M., Roche, B., Meyers, N., & Pfrender, M. E. (2021). Combining natural language processing and metabarcoding to reveal pathogen-environment associations. *PLoS Neglected Tropical Diseases*, 15(4), e0008755. <https://doi.org/10.1371/journal.pntd.0008755>
- Muhammad Awais, Syed, Zhang, H., Li, L., Zhang, W., Awwad, F. A., Ismail, E. A. A., M Ijaz Khan, Raghavan, V., & Hu, J. (2023). AI and machine learning for soil analysis: an assessment of sustainable agricultural practices. *Bioresources and Bioprocessing*, 10(1), 90. <https://doi.org/10.1186/s40643-023-00710-y>
- Muhammad, Wang, S., Wang, J., Ahmar, S., Saeed, S., Shahid Ullah Khan, Xu, X., Chen, H., Javaid Akhter Bhat, & Feng, X. (2022). Applications of artificial intelligence in climate-resilient smart-crop breeding. *International Journal of Molecular Sciences*, 23(19). <https://doi.org/10.3390/ijms231911156>
- Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Almas Kalimoldayev, Adilkhan Symagulov, Vitaly Levashenko, Farida Abdoldina, Viktors Gopejenko, Kirill Yakunin, Muhamedijeva, E., & Yelis, M. (2022). Review of artificial intelligence and machine learning technologies: Classification, restrictions, opportunities and challenges. *Mathematics*, 10(15), 2552. <https://doi.org/10.3390/math10152552>
- Nabwire, S., Suh, H.-K., Kim, M. S., Baek, I., & Cho, B.-K. (2021). Review: Application of artificial intelligence in phenomics. *Sensors*, 21(13), 4363. <https://doi.org/10.3390/s21134363>
- Noé Manuel Montaña, Sandoval, A., Camargo, S., & Sánchez, J. (2010). Los microorganismos: pequeños gigantes. *Elementos: Ciencia Y Cultura*, 17, 15–23.
- Oscar Leonardo García-Navarrete, Correa-Guimaraes, A., & Luis Manuel Navas-Gracia. (2024). Application of convolutional neural networks in weed detection and identification: A systematic review. *Agriculture*, 14(4), 568. <https://doi.org/10.3390/agriculture14040568>
- Peyman Namadi, & Deng, Z. (2023). Deep learning-based ensemble modeling of *Vibrio parahaemolyticus* concentration in marine environment. *Environmental Monitoring and Assessment*, 195(1), 229. <https://doi.org/10.1007/s10661-022-10836-9>
- Pichler, M., & Hartig, F. (2023). Machine learning and deep learning—A review for ecologists. *Methods in Ecology and Evolution*, 14(4), 994–1016. <https://doi.org/10.1111/2041-210X.14061>
- Ricardo Hernández Medina, Kutuzova, S., Knud Nor Nielsen, Johansen, J., Lars Hestbjerg Hansen, Nielsen, M., & Rasmussen, S. (2022). Machine learning and deep learning applications in microbiome research. *ISME Communications*, 2(1). <https://doi.org/10.1038/s43705-022-00182-9>
- Robinson, S. L. (2022). Artificial intelligence for microbial biotechnology: beyond the hype. *Microbial Biotechnology*, 15(1), 65–69. <https://doi.org/10.1111/1751-7915.13943>
- Roy, W., Ying, D., Hui Yi Leong, Kuan Shiong Khoo, Pau Loke Show, & Kit Wayne Chew. (2023). Bridging artificial intelligence and fucoxanthin for the recovery and quantification from microalgae. *Bioengineered*, 14(1). <https://doi.org/10.1080/21655979.2023.2244232>
- Rupshikha Patowary, Devi, A., & Mukherjee, A. K. (2023). Advanced bioremediation by an amalgamation of nanotechnology and modern artificial intelligence for efficient restoration of crude petroleum oil-contaminated sites: a prospective study. *Environmental Science and Pollution Research*, 30(30), 74459–74484. <https://doi.org/10.1007/s11356-023-27698-4>
- Salgado, E. M., Esteves, A. F., Gonçalves, A. L., & Pires, J. C. M. (2023). Microalgal cultures for the remediation of wastewaters with different nitrogen to phosphorus ratios: Process modelling using artificial neural networks. *Environmental Research*, 231, 116076. <https://doi.org/10.1016/j.envres.2023.116076>
- Seyed Mostafa Biazar, Shehadeh, H. A., Mohammad Ali Ghorbani, Golmar Golmohammadi, & Saha, A. (2024). Soil temperature forecasting using a hybrid artificial neural network in Florida subtropical grazinglands agro-ecosystems. *Scientific Reports*, 14(1), 1535. <https://doi.org/10.1038/s41598-023-48025-4>
- Sheikh, H., Prins, C., & Schrijvers, E. (2023). *Artificial intelligence: Definition and background* (pp. 15–41). https://doi.org/10.1007/978-3-031-21448-6_2
- SHEIKH, M., Farooq IQRA, Hamadani AMBREEN, PRAVIN, K. A., Manzoor IKRA, & Yong Suk CHUNG. (2023). Integrating artificial intelligence and high-throughput phenotyping for crop improvement. *Journal of Integrative Agriculture*. <https://doi.org/10.1016/j.jia.2023.10.019>
- Shelke, Y. P., Badge, A. K., & Bankar, N. J. (2023). Applications of artificial intelligence in microbial diagnosis. *Cureus*, 15(11), e49366. <https://doi.org/10.7759/cureus.49366>

- Soma Safeer, Pandey, R. P., Rehman, B., Safdar, T., Ahmad, I., Hasan, S. W., & Ullah, A. (2022). A review of artificial intelligence in water purification and wastewater treatment: Recent advancements. *Journal of Water Process Engineering*, 49, 102974. <https://doi.org/10.1016/j.jwpe.2022.102974>
- Spyridon Mourtzinis, Esker, P. D., Specht, J. E., & Conley, S. P. (2021). Advancing agricultural research using machine learning algorithms. *Scientific Reports*, 11(1), 17879. <https://doi.org/10.1038/s41598-021-97380-7>
- Staša Puškarić, Mateo Sokač, Živana Ninčević, Danijela Šantić, Skejić, S., Tomislav Džoić, Prelesnik, H., & Knut Yngve Børshem. (2024). Extracted spectral signatures from the water column as a tool for the prediction of the structure of a marine microbial community. *Journal of Marine Science and Engineering*, 12(2), 286. <https://doi.org/10.3390/jmse12020286>
- Sun, R., Tu, Z., Fan, L., Qiao, Z., Liu, X., Hu, S., Zheng, G., Wu, Y., Wang, R., & Mi, X. (2020). The correlation analyses of bacterial community composition and spatial factors between freshwater and sediment in Poyang Lake wetland by using artificial neural network (ANN) modeling. *Brazilian Journal of Microbiology* : [Publication of the Brazilian Society for Microbiology], 51(3), 1191–1207. <https://doi.org/10.1007/s42770-020-00285-2>
- Sun, Z., Sandoval, L., Crystal-Ornelas, R., S. Mostafa Mousavi, Wang, J., Lin, C., Cristea, N., Tong, D., Wendy Hawley Carande, Ma, X., Rao, Y., Bednar, J. A., Tan, A., Wang, J., Sanjay Purushotham, Gill, T. E., Chastang, J., Howard, D., Holt, B., & Chandana Gangodagamage. (2022). A review of earth artificial intelligence. *Computers & Geosciences*, 159, 105034. <https://doi.org/10.1016/j.cageo.2022.105034>
- Terence, S., & Geethanjali Purushothaman. (2020). Systematic review of Internet of Things in smart farming. *Transactions on Emerging Telecommunications Technologies*, 31(6). <https://doi.org/10.1002/ett.3958>
- Ubina, N. A., Lan, H.-Y., Cheng, S.-C., Chang, C.-C., Lin, S.-S., Zhang, K.-X., Lu, H.-Y., Cheng, C.-Y., & Hsieh, Y.-Z. (2023). Digital twin-based intelligent fish farming with Artificial Intelligence Internet of Things (AIoT). *Smart Agricultural Technology*, 5, 100285. <https://doi.org/10.1016/j.atech.2023.100285>
- Vaida Bačiulienė, Bilan, Y., Navickas, V., & Lubomír Cívín. (2023). The aspects of artificial intelligence in different phases of the food value and supply chain. *Foods (Basel, Switzerland)*, 12(8). <https://doi.org/10.3390/foods12081654>
- Wahab, A., Muhammad, M., Ullah, S., Abdi, G., Ghulam Mujtaba Shah, Zaman, W., & Ayaz, A. (2024). Agriculture and environmental management through nanotechnology: Eco-friendly nanomaterial synthesis for soil-plant systems, food safety, and sustainability. *Science of the Total Environment*, 926, 171862. <https://doi.org/10.1016/j.scitotenv.2024.171862>
- Walsh, C., Elías Stallard-Olivera, & Fierer, N. (2024). Nine (not so simple) steps: a practical guide to using machine learning in microbial ecology. *MBio*, 15(2). <https://doi.org/10.1128/mbio.02050-23>
- Wang, J., Zhen, J., Hu, W., Chen, S., Lizaga, I., Mojtaba Zeraatpisheh, & Yang, X. (2023). Remote sensing of soil degradation: Progress and perspective. *International Soil and Water Conservation Research*, 11(3), 429–454. <https://doi.org/10.1016/j.iswcr.2023.03.002>
- Wu, J., & Zhao, F. (2023). Machine learning: An effective technical method for future use in assessing the effectiveness of phosphorus-dissolving microbial agromediation. *Frontiers in Bioengineering and Biotechnology*, 11. <https://doi.org/10.3389/fbioe.2023.1189166>
- Xaimarie Hernández-Cruz, Villalobos, J. R., Runger, G., & Neal, G. (2023). Building an intelligent system to identify trends in agricultural markets. *Journal of Cleaner Production*, 425, 138956. <https://doi.org/10.1016/j.jclepro.2023.138956>
- Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., Liu, X., Wu, Y., Dong, F., Qiu, C.-W., Qiu, J., Hua, K., Su, W., Wu, J., Xu, H., Han, Y., Fu, C., Yin, Z., Liu, M., & Roepman, R. (2021). Artificial intelligence: A powerful paradigm for scientific research. *Innovation (Cambridge (Mass.))*, 2(4), 100179. <https://doi.org/10.1016/j.xinn.2021.100179>
- Zhang, J., Li, C., Yin, Y., Zhang, J., & Marcin Grzegorzek. (2023). Applications of artificial neural networks in microorganism image analysis: a comprehensive review from conventional multilayer perceptron to popular convolutional neural network and potential visual transformer. *Artificial Intelligence Review*, 56(2), 1013–1070. <https://doi.org/10.1007/s10462-022-10192-7>
- Zhang, Y., Zhang, D., & Zhang, Z. (2023). A critical review on artificial Intelligence—Based microplastics imaging technology: Recent advances, hot-spots and challenges. *International Journal of Environmental Research and Public Health*, 20(2), 1150. <https://doi.org/10.3390/ijerph20021150>

- Zhao, L., Walkowiak, S., & Dilantha, G. (2023). Artificial intelligence: A promising tool in exploring the phytomicrobiome in managing disease and promoting plant health. *Plants*, 12(9), 1852. <https://doi.org/10.3390/plants12091852>
- Zou, H., Alexandros Sopasakis, Maillard, F., Karlsson, E., Duljas, J., Silwer, S., Ohlsson, P., & Hammer, E. C. (2024). Bacterial community characterization by deep learning aided image analysis in soil chips. *Ecological Informatics*, 81, 102562. <https://doi.org/10.1016/j.ecoinf.2024.102562>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.