



Artículo de revisión / Review article

Aprendizaje automático en agricultura del Cacao: Una revisión sistemática de la literatura

Machine learning in cocoa agriculture: A systematic literature review

Elias Terrazas-Huaman ^{1*}; Anthony Nelson Aliaga-Carbajal ¹; Danger David Castellón-Apaza ¹

¹ Universidad Nacional Amazónica de Madre de Dios, Puerto Maldonado – Perú

Recibido: 10/11/2025

Aceptado: 14/01/2026

Publicado: 30/01/2026

*Autor de correspondencia: eterrazash21-1is@unamad.edu.pe

Resumen: La inteligencia artificial ha adquirido una creciente importancia en diferentes sectores, incluida la agricultura, donde el aprendizaje automático ofrece nuevas posibilidades para optimizar los procesos productivos. En este contexto, el presente estudio analiza la aplicación del machine learning en la agricultura del cacao mediante una revisión sistemática de la literatura científica publicada entre 2020 y 2024. La estrategia de búsqueda consideró las bases y fuentes IEEE Xplore, Springer Link, Scopus, Google Scholar, ACM Digital Library y Semantic Scholar, identificándose inicialmente 10 320 documentos. Tras el proceso de selección, se obtuvieron 66 artículos relevantes para el análisis. Los estudios revisados evidencian que el aprendizaje automático se aplica principalmente en la detección temprana de enfermedades del cacao, la predicción de la productividad de las cosechas y la evaluación y mejora de la calidad del grano. Entre las técnicas más utilizadas destacan las redes neuronales, las máquinas de soporte vectorial (SVM) y los algoritmos de bosque aleatorio, debido a su capacidad para procesar grandes volúmenes de datos. Asimismo, estas técnicas permiten analizar factores relacionados con las condiciones climáticas, características del suelo y presencia de plagas, contribuyendo a mejorar la toma de decisiones y optimizar la producción del cacao.

Palabras clave: agricultura inteligente; clasificación de cultivos; detección de enfermedades; predicción del rendimiento; visión por computadora

Abstract: Artificial intelligence has gained increasing importance across different sectors, including agriculture, where machine learning offers new opportunities to optimize production processes. In this context, the present study analyzes the application of machine learning in cocoa agriculture through a systematic review of the scientific literature published between 2020 and 2024. The search strategy included IEEE Xplore, Springer Link, Scopus, Google Scholar, ACM Digital Library, and Semantic Scholar, initially identifying 10,320 documents. Following the selection process, 66 relevant articles were included in the analysis. The reviewed studies show that machine learning is mainly applied to the early detection of cocoa diseases, crop yield prediction, and the assessment and improvement of bean quality. The most frequently used techniques include neural networks, support vector machines (SVM), and random forest algorithms due to their ability to process large volumes of data. Furthermore, these techniques enable the analysis of factors related to climatic conditions, soil characteristics, and pest occurrence, thereby contributing to improved decision-making and the optimization of cocoa production.

Keywords: Crop Classification; Disease Detection; Precision Farming; Yield Prediction; Computer Vision

1. Introducción

La agricultura del cacao, fundamental para la producción de chocolate y otros productos derivados, ha sido un pilar económico en muchos países tropicales. Sin embargo, la industria enfrenta diversos desafíos, como el cambio climático, el aumento de plagas y enfermedades, así como la presión por mejorar la sostenibilidad y la rentabilidad de los cultivos. En este contexto, el uso de tecnologías emergentes, como el machine learning, se está convirtiendo en una herramienta crucial para optimizar el rendimiento y la productividad en el cultivo de cacao. Las nuevas condiciones ambientales exigen la adaptación de las prácticas de cultivo del cacao para mantener la productividad y la sostenibilidad (Caicedo-Vargas et al., 2023).

1.1 Contexto Histórico y Actual de la Industria del Cacao

El cacao tiene una rica historia que se remonta a las antiguas civilizaciones mesoamericanas, donde se utilizaba como moneda y en rituales sagrados. Con la llegada de los colonizadores europeos, el cacao se introdujo en otras partes del mundo, convirtiéndose en un producto de lujo en el Viejo Continente. Hoy en día, el cacao se cultiva principalmente en países de África, América Latina y Asia, siendo Costa de Marfil y Ghana los principales productores mundiales (Cilas & Bastide, 2020).

pese a que hay una gran importancia económica en el cacao, la industria del cacao se enfrenta a serios retos. La producción de cacao es sensible a las variaciones climáticas; condiciones extremas como sequías o lluvias excesivas pueden afectar la calidad y cantidad de la cosecha. Además, las enfermedades, como la moniliasis y la podredumbre negra, han devastado plantaciones en diversas regiones, amenazando la viabilidad de muchas explotaciones agrícolas (Caicedo-Vargas et al., 2023).

1.2 Fundamentos de Machine Learning

El machine learning es una parte de la inteligencia artificial que se dedica a crear algoritmos y modelos que permiten a las computadoras aprender de los datos. Esto les ayuda a hacer predicciones o tomar decisiones sin necesidad de ser programadas específicamente para cada tarea. Los algoritmos de machine learning se pueden agrupar en tres categorías principales: aprendizaje supervisado, en el que se entrena a la máquina con ejemplos; aprendizaje no supervisado, donde la máquina encuentra patrones por sí sola; y aprendizaje por refuerzo, que se basa en recompensar a la máquina por sus decisiones correctas.

1.2.1 Aprendizaje Supervisado

Este enfoque de aprendizaje se basa en datos etiquetados para capacitar a un modelo. Por ejemplo, se puede usar un conjunto de datos que incluya información sobre el rendimiento de cultivos de cacao en diversas condiciones climáticas para prever rendimientos futuros. Para examinar estos datos, se utilizan diferentes algoritmos, como la regresión lineal, los bosques aleatorios y las redes neuronales (Khade et al., 2022).

1.2.2 Aprendizaje No Supervisado

En este caso, el modelo trabaja con datos no etiquetados y busca patrones o agrupaciones en los datos. Esto puede ser útil para identificar grupos de variables que afectan el rendimiento de los cultivos de cacao (Lamos-Díaz et al., 2020).

1.2.3 Aprendizaje por Refuerzo

Este enfoque se fundamenta en la idea de que un agente puede aprender a tomar decisiones a través de su interacción con el entorno, obteniendo recompensas o castigos. Aunque es menos frecuente en el ámbito agrícola, tiene el potencial de optimizar las prácticas agrícolas mediante la experimentación. El modelado basado en agentes (ABM) simula las interacciones entre diferentes agentes en los sistemas agrícolas, como agricultores, cultivos y plagas, con el fin de identificar estrategias óptimas para mejorar el rendimiento (Shaji & Bharadwaj, 2024).

1.3 Aplicaciones Específicas en el Cultivo de Cacao

El uso de machine learning en la agricultura del cacao se ha manifestado en diferentes áreas, cada una abordando aspectos específicos del cultivo. A continuación, se presentan algunas aplicaciones clave:

1.3.1 Predicción del Rendimiento

Diversos estudios han demostrado la eficacia de los algoritmos de machine learning para predecir el rendimiento de los cultivos de cacao. Por ejemplo, se han utilizado modelos como Support Vector Machines (SVM), Random Forest y Gradient Boosting para analizar datos históricos y climáticos, lo que permite a los agricultores anticipar la producción y planificar adecuadamente (Lamos-Díaz et al., 2020).

1.3.2 Identificación de Factores Críticos

Mediante el análisis de datos, el machine learning puede ayudar a identificar cuáles son las variables más influyentes en el rendimiento del cacao. Investigaciones recientes han señalado que factores como la radiación solar, la humedad del suelo y las precipitaciones son determinantes para el éxito de la cosecha (Ayikpa et al., 2024; Cock et al., 2023). Este conocimiento permite a los agricultores ajustar sus prácticas de manejo para mejorar la productividad.

1.3.3 Detección de Enfermedades

Ante el incremento de plagas y enfermedades que ponen en riesgo los cultivos de cacao, se ha recurrido al machine learning para crear modelos de detección temprana. Por ejemplo, se han desarrollado aplicaciones móviles que emplean técnicas de visión por computadora y aprendizaje profundo para reconocer enfermedades en las mazorcas de cacao, lo que permite a los agricultores actuar rápidamente con medidas correctivas (Mamadou et al., 2023).

1.3.4 Optimización del Riego y Fertilización

La gestión del agua y los nutrientes es esencial en la agricultura del cacao. Los modelos de machine learning pueden analizar datos de sensores sobre la humedad del suelo y otros factores ambientales para optimizar los programas de riego y fertilización, asegurando que las plantas reciban los insumos adecuados en el momento adecuado (Lamos-Díaz et al., 2020).

1.4 Variables Críticas que Afectan el Rendimiento

El rendimiento del cacao es influenciado por una variedad de factores. Algunos de los más críticos incluyen:

1.4.1 Condiciones Climáticas

La temperatura, la humedad y la cantidad de lluvia son de fundamental importancia. Investigaciones han demostrado que la radiación solar un mes antes de la cosecha, así como las lluvias y la temperatura, son variables clave para explicar la variabilidad en el rendimiento del cacao. El aumento de las temperaturas máximas repercute negativamente en el rendimiento del cacao, con correlaciones significativas observadas en estudios realizados en Ghana y Nigeria (Lawal & Omonona, 2014; Wiah, 2017).

1.4.2 Variedad de Cacao

Diferentes variedades de cacao pueden tener distintos requerimientos y tolerancias a las condiciones ambientales. El machine learning puede ayudar a determinar qué variedades son más adecuadas para condiciones específicas, optimizando así la selección de cultivos. El aprendizaje automático puede facilitar la identificación de estos rasgos en varios genotipos, lo que permite seleccionar variedades resistentes a la sequía que puedan prosperar en climas cambiantes (Araújo et al., 2024).

2. Materiales y métodos

El estudio de machine learning aplicado a la agricultura del cacao, necesita una definición precisa de preguntas de investigación. Estas preguntas funcionan como un marco orientador, facilitando la recopilación de información en fuentes confiables y permitiendo analizar los datos de manera efectiva para alcanzar los objetivos propuestos.

Para visualizar las tendencias de investigación predominantes y detectar los temas clave dentro del campo del machine learning en la agricultura del cacao, se puede emplear un mapa de palabras clave. Esta herramienta, sugerida por Kitchenham, permite identificar la frecuencia de términos relevantes en la literatura científica, facilitando la detección de áreas de interés como predicción de enfermedades, optimización de cultivos y sostenibilidad agrícola. La construcción de este mapa tiene que ver con la captación de datos de diferentes fuentes, como IEEE Xplore, Springer Link, Google Scholar, ACM Digital Library y Semantic Scholar, seguidos de un análisis exhaustivo de las palabras más repetidas en los títulos como también resúmenes y palabras clave de los artículos vistos




Figura 1. Proceso RSL

2.1 Elaboración de preguntas

Se formula una pregunta de investigación general (RQG) y, adicionalmente, se proponen varias preguntas de investigación (RQ) específicas junto con sus respectivos objetivos, como se muestra en la Tabla 1 a continuación.

- 1 ¿Cómo puede el machine learning contribuir a optimizar la productividad, sostenibilidad y manejo de los cultivos de cacao?
- 2 ¿Qué problemas comunes en el cultivo de cacao pueden resolverse utilizando machine learning?
- 3 ¿Cuáles son las técnicas de machine learning más efectivas para predecir enfermedades en los cultivos de cacao?
- 4 ¿Cómo contribuyen los modelos de machine learning al aumento de la productividad del cacao sin comprometer la sostenibilidad ambiental?
- 5 ¿Qué datos son críticos para desarrollar modelos de machine learning aplicados al cultivo de cacao?

Tabla 1. Preguntas y objetivos de la investigación

Pregunta de investigación	Objetivos
- RQG: ¿Cómo puede el machine learning contribuir a optimizar la productividad, sostenibilidad y manejo de los cultivos de cacao? - RQ1: ¿Qué problemas comunes en el cultivo de cacao pueden resolverse utilizando machine learning? - RQ2: ¿Cuáles son las técnicas de machine learning más efectivas para predecir enfermedades en los cultivos de cacao? - RQ3: ¿Cómo contribuyen los modelos de machine learning al aumento de la productividad del cacao sin comprometer la sostenibilidad ambiental? - RQ4: ¿Qué datos son críticos para desarrollar modelos de machine learning aplicados al cultivo de cacao? - RQ5: ¿De qué manera el machine learning puede optimizar la cadena de suministro y la calidad del cacao desde la cosecha hasta su comercialización?	- El machine learning, puede mejorar la productividad, sostenibilidad y manejo de los cultivos de cacao. Estas tecnologías permiten mejorar la gestión de los cultivos al dar datos en tiempo inmediato sobre condiciones ambientales, salud del suelo y necesidades de riego - El impacto del machine learning se observa en el cultivo de cacao, donde se pueden resolver problemas comunes como el monitoreo de plagas y enfermedades, la optimización del uso de recursos hídricos y la previsión de rendimientos - Las técnicas efectivas de machine learning para predecir enfermedades en cultivos de cacao incluyen redes neuronales y algoritmos de clasificación. - Los modelos de machine learning contribuyen al aumento de la productividad del cacao al optimizar el uso de recursos y prever rendimientos, sin comprometer la sostenibilidad ambiental. - Los datos críticos para desarrollar modelos de machine learning aplicados al cultivo de cacao incluyen información sobre clima, salud del suelo y plagas. - El machine learning puede predecir la demanda, mejorar la logística de transporte y asegurar la trazabilidad desde la cosecha hasta la comercialización.

2.2 Categorización o identificación de fuentes

Para poder garantizar un buen trabajo se hará usando las fuentes como: Google Scholar, Scopus, Ardi, MDPI y otras fuentes confiables; esto con el fin de tener información verídica y revisada adecuadamente. Además, se llevará a cabo un proceso de categorización de las fuentes para así clasificarlas en diferentes tipos, como fuentes primarias, secundarias y terciarias. Esto permitirá una mejor organización de la información y también la fácil identificación de los estudios más relevantes a la hora de selección de recolección de artículos.

2.3 Recolección de información

Tabla 2. Descriptores de búsqueda

Descriptor	Descripción
- machine learning / deep learning - cocoa / cocoa agriculture	- Independiente Variable - Variable dependiente

Tabla 3. Descriptores de búsqueda y sus sinónimos

Pregunta de investigación	Objetivos
- ResearchGate - IEEE Xplore - Google Scholar - MDPI - ScienseDirect	((Abstract:(\("machine learning" OR "deep learning"\) AND \((cocoa OR "cocoa agriculture"\)) OR (TitleCombined:(\("machine learning" OR "deep learning"\) AND \((cocoa OR "cocoa agriculture"\))))) ("Document Title":"machine learning" OR "Document Title":"deep learning" OR "Abstract":"machine learning" OR "Abstract":"deep learning") AND ("Document Title":cocoa OR

	"Document Title":"cocoa agriculture" OR "Abstract":cocoa OR "Abstract":cocoa agriculture")
•	intitle:"machine learning" OR intitle:"deep learning" AND ("cocoa" OR "cocoa agriculture")
•	(TITLE("machine learning" OR "deep learning") OR ABSTRACT("machine learning" OR "deep learning")) AND (TITLE("cocoa" OR "cocoa agriculture") OR ABSTRACT("cocoa" OR "cocoa agriculture"))
•	(TITLE("machine learning" OR "deep learning") OR ABS("machine learning" OR "deep learning")) AND (TITLE("cocoa" OR "cocoa agriculture") OR ABS("cocoa" OR "cocoa agriculture"))

2.4 Investigaciones seleccionadas

En esta sección se muestra el número de resultados por búsqueda de las fuentes de información antes mencionadas, así como se muestra en la figura 2




Figura 2. Número de artículos por fuente

2.5 Criterio de rechazo

Luego de obtener los trabajos, el siguiente paso es seleccionarlos para su evaluación y determinar si son aptos para la investigación. Para ello se utilizaron cuatro filtros con ocho criterios de exclusión (CE), que se detallan a continuación:

- EC1: Los trabajos tienen menos de 5 años.
- EC2: Los artículos no están escritos en inglés.
- EC3: Los artículos no han sido publicados en congresos o revistas.
- EC4: Estudios que no aborden específicamente el uso de machine learning en la agricultura del cacao.
- EC5: Los artículos son trabajos de los cuales no se obtienen resultados relevantes.
- EC6: Artículos que no presenten resultados empíricos o aplicados del machine learning en el contexto agrícola.
- EC7: Documentos de los cuales no se puede acceder al texto completo.
- EC8: Estudios que carezcan de una metodología clara o que no presenten un análisis riguroso.

2.7 Captura de datos

Ahora, se inició el proceso de extracción de los artículos más relevantes con el objetivo de abordar con precisión las preguntas de investigación establecidas. La información extraída incluyó: número de referencia, título del artículo, URL, fuente, año, países, ISSN, tipo de publicación, nombre de la publicación, autores, afiliaciones, índice H, metodología de investigación, número de citas, resumen, palabras clave, discusión. y conclusión. Para cuartilla, categorizar los artículos se utilizó la herramienta Mendeley Desktop, como se muestra en la figura 3.

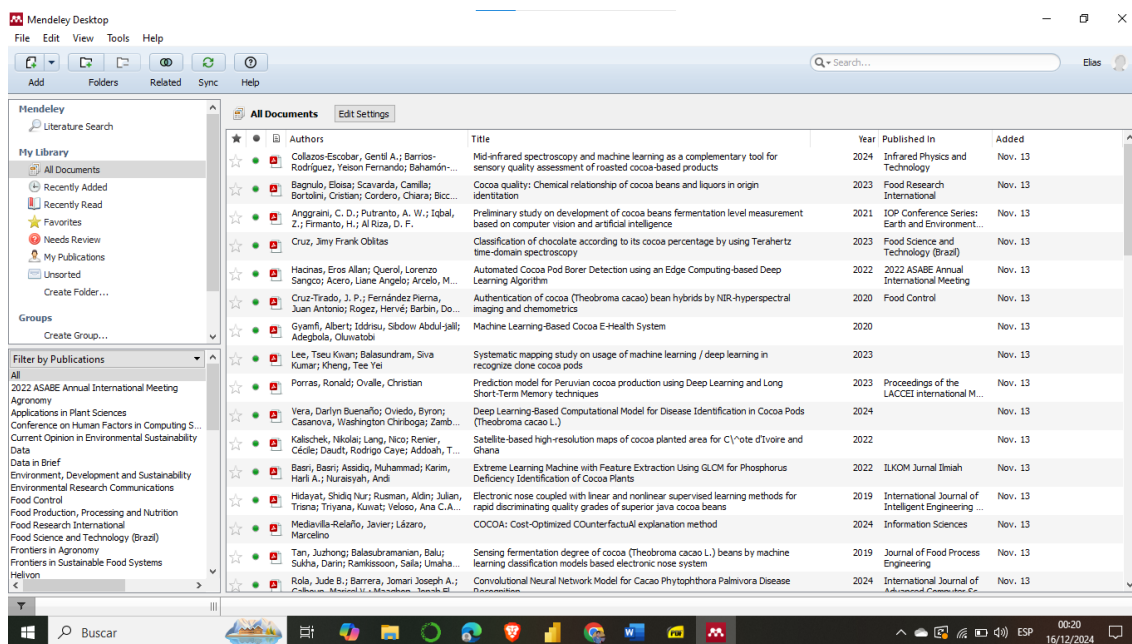


Figura 3. Informes de artículos

3. Resultado

Se examinan las áreas de aplicación destacada y los niveles de la calidad de las fuentes, las redes de coautoría de las investigaciones y los grupos de artículos con títulos parecidos. Así mismo se tendrá una visión integral de los resultados alcanzados que contribuyen a una comprensión más profunda de este campo de estudio.



Figura 4. Red bibliométrica de autores

3.1 Descripción general de estudios

Los hallazgos generales obtenidos en esta revisión se presentan a continuación. La Figura 5 ilustra el porcentaje de artículos según los tipos de publicación. En este estudio, se seleccionaron 66 artículos, estableciendo el criterio de incluir únicamente artículos de revistas y congresos. La Figura 5 revela que el 92% son journal, mientras que sólo el 8% son de conference, del total de tipos de artículos considerados.




Figura 5. Porcentaje de journal y conference

Diagrama de Sankey - Fuente v




Figura 6. Diagrama Sankey

El diagrama de Sankey evidencia la distribución de las fuentes bibliográficas según los cuartiles de las publicaciones analizadas. Se observa que Google Scholar concentra el mayor volumen de estudios, con una participación importante de publicaciones pertenecientes principalmente al Q1, aunque también presenta aportes hacia Q2, Q3 y SQ. Por su parte, MDPI constituye otra fuente relevante, cuyos documentos se distribuyen mayoritariamente entre Q1 y Q2. Scopus y ScienceDirect presentan una participación menor, pero contribuyen con publicaciones ubicadas en diferentes niveles de impacto. Springer muestra la menor presencia dentro del conjunto analizado. En términos de calidad científica, el flujo hacia Q1 es claramente predominante, lo que indica una importante presencia de investigaciones publicadas en revistas de alto impacto. Asimismo, se identifican documentos correspondientes a Q2 y Q3, aunque en menor proporción. Las publicaciones clasificadas como SQ representan una participación intermedia y corresponden a fuentes sin cuartil identificado. En conjunto, los resultados muestran que la literatura

seleccionada presenta una concentración favorable en publicaciones de alto impacto, fortaleciendo la calidad de la evidencia utilizada en la revisión sistemática.




Figura 7. Distribución anual de los artículos seleccionados según el cuartil de las revistas científicas

La figura 7 evidencia un crecimiento progresivo de las publicaciones entre 2019 y 2023, alcanzando su mayor nivel en 2023, seguido de una disminución en 2024. Las publicaciones en revistas Q1 predominan durante la mayor parte del periodo, especialmente en 2023 y 2024, lo que refleja una importante presencia de estudios publicados en revistas de alto impacto. Asimismo, se observa una participación menor de artículos Q2, Q3 y sin cuartil (SQ), evidenciando que la literatura seleccionada se concentra principalmente en fuentes científicas de elevada calidad.




Figura 8. Distribución geográfica de los estudios seleccionados según país de procedencia

La figura 8 muestra una amplia distribución geográfica de los estudios analizados, con presencia de investigaciones procedentes de América, Europa, Asia, África y Oceanía. Se observa una

concentración importante de publicaciones en Europa y América, destacando también la participación de países asiáticos vinculados con la producción y estudio de cultivos tropicales. Asimismo, países latinoamericanos como Perú, Colombia, Ecuador y Brasil forman parte de la producción científica identificada. Esta diversidad geográfica evidencia el interés internacional por la aplicación del aprendizaje automático en el ámbito agrícola, permitiendo integrar experiencias desarrolladas en diferentes contextos productivos y tecnológicos.




Figura 9. Nube de palabras de los términos predominantes en los estudios seleccionados

La figura 9 muestra los términos con mayor presencia en los estudios analizados, destacando “cocoa”, “machine learning”, “classification”, “deep learning” y “using”, lo que evidencia una marcada orientación hacia la aplicación de técnicas de inteligencia artificial en el cacao. Asimismo, aparecen términos como CNN, neural, algorithm, prediction, disease, detection, quality y bean, asociados principalmente con la clasificación, detección de enfermedades, predicción y evaluación de la calidad del grano. En conjunto, la nube de palabras permite identificar que las investigaciones se concentran principalmente en el uso de aprendizaje automático y aprendizaje profundo para resolver problemas relacionados con la producción, sanidad y calidad del cacao.

4. Conclusiones

El uso del machine learning en la agricultura del cacao se ha consolidado como una herramienta relevante para enfrentar diversos desafíos relacionados con la productividad, sanidad y sostenibilidad del cultivo. A partir de la revisión sistemática de 68 estudios, se identificó que técnicas como las redes neuronales, las máquinas de soporte vectorial y los algoritmos de bosque aleatorio son utilizadas principalmente para la detección temprana de enfermedades, predicción del rendimiento, evaluación de la calidad del grano y optimización del riego y la fertilización. Asimismo, la integración de estos modelos con sensores y plataformas digitales permite analizar variables como las condiciones climáticas y las características del suelo, proporcionando información que favorece una toma de decisiones más precisa y contribuye a reducir pérdidas y mejorar la gestión de los cultivos.

A pesar de estos avances, persisten desafíos relacionados con la disponibilidad y calidad de los datos, el acceso a tecnologías y la capacitación de los agricultores, especialmente en regiones productoras con limitaciones tecnológicas. En este sentido, el machine learning representa una

oportunidad para impulsar una agricultura del cacao más eficiente, rentable y sostenible; sin embargo, su implementación requiere fortalecer la generación de datos confiables, facilitar el acceso a herramientas tecnológicas y promover la colaboración entre investigadores, productores e instituciones. De esta manera, será posible ampliar la adopción de estas tecnologías y favorecer su aplicación efectiva en diferentes contextos de producción de cacao.

Financiamiento

Ninguno.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Contribución de autores

Los autores declaran haber realizado todas las etapas de la investigación y redacción del manuscrito.

Referencias bibliográficas

- Araújo, M. S., Chaves, S. F. S., Guimarães, M. H. D., Dias, L. A. S., & Aguilar, M. A. G. (2024). Multi-trait selection for nutritional and physiological quality of cacao genotypes in irrigated and non-irrigated environments. *Scientific Reports*, 14(1), 6368. <https://doi.org/10.1038/s41598-024-56556-7>
- Ayikpa, K. J., Gouton, P., Mamadou, D., & Ballo, A. B. (2024). Classification of cocoa beans by analyzing spectral measurements using machine learning and genetic algorithm. *Journal of Imaging*, 10(1). <https://doi.org/10.3390/jimaging10010019>
- Caicedo-Vargas, C., Pérez-Neira, D., Abad-González, J., & Gallar, D. (2023). Agroecology as a means to improve energy metabolism and economic management in smallholder cocoa farmers in the Ecuadorian Amazon. *Sustainable Production and Consumption*, 41, 201–212. <https://doi.org/10.1016/j.spc.2023.08.005>
- Cilas, C., & Bastide, P. (2020). Challenges to cocoa production in the face of climate change and the spread of pests and diseases. *Agronomy*, 10(9), 1232. <https://doi.org/10.3390/agronomy10091232>
- Cock, J., Jiménez, D., Dorado, H., & Oberthür, T. (2023). Operations research and machine learning to manage risk and optimize production practices in agriculture: Good and bad experience. *Current Opinion in Environmental Sustainability*, 62, 101278. <https://doi.org/10.1016/j.cosust.2023.101278>
- Khade, S., Malaye, V., Mhase, S., Shitole, A., & Shirsath, S. (2022). Crop yield prediction using machine learning. *International Journal for Science Technology and Engineering*, 10(5), 5308–5313. <https://doi.org/10.22214/ijraset.2022.43191>
- Lamos-Díaz, H., Puentes-Garzón, D. E., & Zarate-Caicedo, D. A. (2020). Comparison between machine learning models for yield forecast in cocoa crops in Santander, Colombia. *Revista Facultad de Ingeniería*, 29(54), e10853. <https://doi.org/10.19053/01211129.v29.n54.2020.10853>

- Lawal, J. O., & Omonona, B. T. (2014). The effects of rainfall and other weather parameters on cocoa production in Nigeria. 5(4), 518–523. <https://doi.org/10.14295/CS.V5I4.365>
- Mamadou, D., Ayikpa, K. J., Ballo, A. B., & Kouassi, B. M. (2023). Cocoa pods diseases detection by MobileNet confluence and classification algorithms. *International Journal of Advanced Computer Science and Applications*, 14(9), 344–352. <https://doi.org/10.14569/IJACSA.2023.0140937>
- Shaji, D., & Bharadwaj, A. (2024). Improving farm yield through agent based modeling. *International Journal for Multidisciplinary Research*, 6(2). <https://doi.org/10.36948/ijfmr.2024.v06i02.16664>
- Wiah, E. N. (2017). Impact of climate change on cocoa yield in Ghana using vector autoregressive model. 1(2), 32–39.