

# Inteligencia artificial para detección y diagnóstico de enfermedades en cultivos de arroz

Elen Yanina Aguirre Rodríguez  
*Programa de Posgrado em Engenharia*  
*Universidade Estadual Paulista*  
Guaratinguetá, SP, Brasil  
ORCID: 0000-0002-3829-4118

Elias Carlos Aguirre Rodríguez  
*Programa de Posgrado em Engenharia*  
*Universidade Estadual Paulista*  
Guaratinguetá, SP, Brasil  
ORCID: 0000-0003-1120-1708

Juan Pedro Santos Fernández  
*Departamento de Ingeniería de Sistemas*  
*Universidad Nacional de Trujillo*  
Trujillo, Perú  
ORCID: 0000-0002-8882-9256

Luiz Fernando Costa Nascimento  
*Departamento de Química e Energia*  
*Universidade Estadual Paulista*  
Guaratinguetá, SP, Brasil  
ORCID: 0000-0001-9793-750X

Aneirson Francisco da Silva  
*Departamento de Produção*  
*Universidade Estadual Paulista*  
Guaratinguetá, SP, Brasil  
ORCID: 0000-0002-2215-0734

Fernando Augusto Silva Marins  
*Departamento de Produção*  
*Universidade Estadual Paulista*  
Guaratinguetá, SP, Brasil  
ORCID: 0000-0001-6510-9187

**Resumen** – El arroz es uno de los principales alimentos a nivel mundial, y las enfermedades en los cultivos de arroz pueden provocar la pérdida de gran parte de la producción. Además, se ha observado en la literatura un creciente interés por la aplicación de herramientas de inteligencia artificial para la predicción, detección y diagnóstico de enfermedades o plagas en el arroz, ya que ayudan a los expertos a tomar decisiones. El objetivo principal de este trabajo fue analizar las publicaciones donde se aplicó inteligencia artificial para detectar enfermedades en el arroz, explorando las principales técnicas utilizadas. El análisis realizado consistió en evaluar los indicadores bibliométricos de documentos publicados entre 2007 y 2022. Esta investigación aporta información relevante que ayudará en el desarrollo de futuros estudios.

**Palabras clave** – Inteligencia artificial, detección de enfermedades, diagnóstico de enfermedades, hojas de arroz, revisión de la literatura.

**Abstract**—Rice is one of the world's main foods, and diseases in rice crops can cause the loss of much of the production. In addition, a growing interest in the application of artificial intelligence tools for the prediction, detection, or diagnosis of diseases in rice has been observed in the literature, since they help experts to make decisions. The main objective of this work was to analyze the publications where artificial intelligence was applied to detect diseases in rice, exploring the main techniques used. The analysis consisted of evaluating the bibliometric indicators of documents published between 2007 and 2022. This research provides relevant information that will help in the development of future studies.

**Index Terms**—Artificial intelligence, disease detection, disease diagnosis, rice leaves, literature review.

## I. INTRODUCCIÓN

El arroz es uno de los principales alimentos a nivel mundial, ya que aproximadamente la mitad de la población la consume como parte esencial de su dieta. De acuerdo con el Foro Económico Mundial, solo en 2019 se produjeron 756 millones de toneladas de arroz en todo el mundo, y los países

responsables de la mayor cantidad de arroz producido fueron China (28,2%) e India (23,7%) [1]. Lo mismo es reflejado en la evaluación de la producción por continente, en la que el continente asiático (90,6%) fue el mayor productor de arroz de 1994 a 2019, seguido de los continentes de América (5,2%), África (3,5%), Europa (0,6%) y Oceanía (0,1%) [2].

Así mismo, proyecciones globales sobre la expansión de la población han demostrado que la producción de alimentos esenciales debe aumentar en un 70% entre 2005 y 2050, para garantizar la seguridad alimentaria y nutricional de la población [3]–[5]. Así, teniendo en cuenta que el arroz es uno de los alimentos básicos de consumo, las proyecciones sobre su producción indican que para el 2035 su producción deberá incrementarse en un 26%, para atender la demanda en las regiones de América Latina y África [6].

Por lo tanto, mejorar la eficiencia, productividad y rentabilidad del arroz es de vital importancia para alcanzar las proyecciones establecidas, y, al mismo tiempo, poder alcanzar los Objetivos de Desarrollo Sostenible (ODS, en inglés *Sustainable Development Goals*). En particular, los ODS sobre reducción de la pobreza (objetivo 1), reducción del hambre mediante el logro de la seguridad alimentaria (objetivo 2) y producción y consumo sostenibles (objetivo 12) [7].

Por otro lado, las enfermedades o plagas en los cultivos de arroz ocasionan que la seguridad alimentaria de la población se vea afectada, puesto que provocan la pérdida de gran parte de la producción [8], y estas pérdidas pueden ocasionar que los costos de producción aumenten y no se satisfaga la demanda. Por consiguiente, es importante monitorear los cultivos de arroz para el diagnóstico de enfermedades para un tratamiento preventivo, con el fin de controlar sus efectos negativos asegurando la minimización de pérdidas y una alta calidad en la producción de arroz. Asimismo, el tratamiento adecuado de una enfermedad en un campo de arroz requiere un alto nivel de experiencia por parte del especialista, para la correcta identificación del problema [4], [9]. De modo

que, agricultores o especialistas con menor experiencia pueden atribuir un diagnóstico erróneo, lo que conduce a la aplicación innecesaria o incorrecta de pesticidas para controlar el problema en el arroz [5].

De acuerdo con la literatura, ha surgido un interés creciente por el uso de herramientas de Inteligencia Artificial (IA, en inglés *Artificial intelligence*) para la predicción o detección de plagas o enfermedades de diferentes cultivos, incluso para la identificación de enfermedades del arroz [4], [5], [9]–[14]. Por consiguiente, la IA puede ayudar a los expertos a tomar decisiones oportunas de una manera más rápida y sencilla [5], [9], [10]. Estas herramientas permiten una detección automática y rápida de las enfermedades en los cultivos, generando que sea aplicado un tratamiento oportuno, y consecuentemente sean reducidas las pérdidas de la producción de arroz.

En este contexto, este documento propone explorar y analizar artículos publicados sobre la aplicación de IA para detección y diagnóstico de enfermedades en el arroz. Este trabajo adoptó un enfoque bibliométrico y sistemático para proporcionar una comprensión amplia de la aplicación de IA en esta área de estudio.

El artículo está estructurado de la siguiente manera: la Sección II presenta los materiales y métodos de este estudio. La Sección III describe los resultados, detallando las informaciones relevantes con respecto a la aplicación de IA para la detección y diagnóstico de enfermedades en cultivos de arroz. Finalmente, la Sección IV presenta las conclusiones, seguidas de las referencias bibliográficas.

## II. MATERIALES Y MÉTODOS

La Fig. 1 presenta las etapas del procedimiento metodológico seguido para el desarrollo de este estudio.

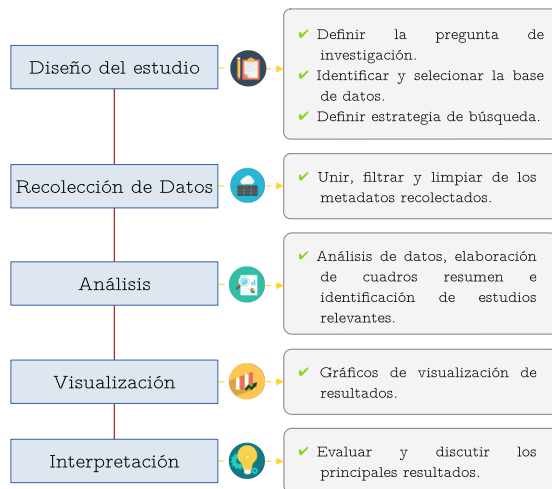


Fig. 1: Etapas del procedimiento metodológico.

El procedimiento metodológico de la Fig. 1 es una adaptación de [15], que consta de 5 etapas que están descritas a continuación:

### A. Diseño del Estudio

En el análisis realizado en este estudio se buscó dar respuesta a las siguientes preguntas de investigación:

- ¿Cuál es el estado actual y tendencia de la aplicación de IA en la detección de enfermedades en hojas de arroz?
- ¿Cuáles son los países con mayor número de investigaciones sobre IA aplicada a la detección de enfermedades en cultivos de arroz?
- ¿Cuál es la tendencia de los temas tratados en las investigaciones sobre IA y cultivos de arroz?
- ¿Cuáles son las investigaciones más representativas en esta área y qué técnicas de IA abordaron?

Asimismo, para responder a estas preguntas de investigación fueron analizados los artículos extraídos de las bases de datos de Scopus [https://www.scopus.com/], *Web of Science* [https://www.webofscience.com/] e IEEE Xplore [https://ieeexplore.ieee.org/Xplore/home.jsp], ya que brindan una amplia gama de artículos indexados.

Los términos utilizados para la búsqueda de documentos fueron “artificial intelligence”, “supervised learning”, “machine learning”, “deep learning”, “rice health”, “rice disease detection”, “rice disease diagnosis”, y “rice leaves”. La búsqueda de artículos en Scopus fue basada en “Article title, abstract, keywords”, la búsqueda en *Web of Science* en “All fields”, y en IEEE Xplore en “All Metadata”. La búsqueda fue refinada para incluir sólo artículos originales y artículos de actas. Además, solo se consideraron artículos en etapa final de publicación hasta 30 de agosto de 2022.

### B. Recolección de Datos

La búsqueda de artículos resultó en 115 documentos encontrados en Scopus, 34 en *Web of Science* y 23 en IEEE Xplore, como se muestra en la Tabla I.

TABLA I  
NÚMERO DE ARTÍCULOS ENCONTRADOS EN SCOPUS, *Web of Science* E IEEE XPLORE

Palabras clave de búsqueda	Scopus	WoS <sup>a</sup>	IEEE <sup>b</sup>
(“Artificial Intelligence” OR “supervised learning” OR “machine learning” OR “deep learning”)	864.146	683.228	391.352
(“rice health” OR “rice disease detection” OR “rice disease diagnosis” OR “rice leaves”)	3.137	1.770	59
(“Artificial Intelligence” OR “supervised learning” OR “machine learning” OR “deep learning”) AND (“rice health” OR “rice disease detection” OR “rice disease diagnosis” OR “rice leaves”)	115	34	23

<sup>a</sup>WoS: *Web of Science*, <sup>b</sup>IEEE: IEEE Xplore .

A partir de la base de datos recopilada fue realizado un filtrado para encontrar los artículos duplicados. Fueron encontrados 31 documentos duplicados, lo que resultó en un único conjunto de metadatos de 122 artículos (84 artículos únicos en Scopus, 3 en *Web of Science* y 4 en IEEE Xplore), que se unificaron en un archivo de acuerdo con el formato




Fig. 2: Publicaciones y citas acumuladas en el periodo 2007 - 2022

Scopus. La unión del documento fue realizada en el editor LibreOffice v.6.4.7.

C. Análisis, Visualización e Interpretación

El análisis de los indicadores bibliométricos fue realizado mediante el software R v.4.2.1, específicamente utilizando el paquete Bibliometrix [16]. Además, Python v.3.9.7 y Jupyter-notebook v.6.4.6. fueron utilizados para el análisis de correlación entre el número de publicaciones y el número de citas. Fue utilizado el coeficiente de Spearman ( $r_s$ ) para el análisis de correlación, siendo que el  $r_s$  varía entre  $[-1, 1]$ , indicando una asociación negativa y positiva, respectivamente [17]. El nivel de significancia estadística considerado fue 5%.

Los gráficos de visualización de los indicadores fueron producidos con Python. Con VOSviewer v.1.6.17 se elaboraron los mapas de red de co-ocurrencia de términos y los mapas de colaboración internacional.

III. RESULTADOS Y DISCUSIÓN

Para responder a las preguntas de investigación planteadas en la sección anterior, se realizó un análisis de contenido de la literatura relevante extraída de Scopus, Web of Science e IEEE Xplore. La Tabla II presenta el análisis descriptivo de los metadatos recopilados.

TABLA II  
INFORMACIÓN SOBRE LOS METADATOS ANALIZADOS

Descripción	Resultados
Período en años	2007-2022
Número total de documentos	122
Tipo de documento: artículo	69
Tipo de documento: artículos de actas	53
Tasa anual de crecimiento	18,44%
Número de fuentes de publicación	97
Número total de citas	1.175
Promedio de citas por documento	9,63
Número total de palabras clave	336
Número total de autores	443
Número de documentos de un solo autor	5
Número de documentos de varios autores	117
Proporción de colaboración internacional	17,21

De acuerdo con los documentos analizados (122 documentos), 69 fueron artículos originales y 53 corresponden

a artículos de actas. La Fig. 2 muestra la evolución de las publicaciones y citas acumuladas en esta área de investigación en el periodo 2007-2022. El análisis de correlación mostró la existencia de una relación positiva significativa entre el número total de publicaciones y el número total de citas por año ( $r_s = 0,86$ ,  $p$ -valor  $< 0,001$ ).

Además, en la Fig. 2 puede ser observado que las investigaciones sobre la aplicación de IA en la detección de enfermedades en cultivos de arroz iniciaron a partir de 2007. Sin embargo, si bien en 2007 se registraron 3 publicaciones, a partir de 2016 hubo un interés creciente por investigar la integración de IA, observándose el mismo comportamiento cuando se analizaron las citas. Asimismo, la tasa de crecimiento anual de las publicaciones fue igual al 18,44%.

El número total de citas fue de 1.175, el promedio de citas por artículo fue de 9,63 (Tabla II), además de que el 97,87% del total de citas corresponden a documentos publicados en los últimos seis años (Fig. 2). Al evaluar el índice h (métrica de la relación entre la productividad y el impacto de las publicaciones) y el número de documentos anuales se observó una relación positiva significativa ( $r_s = 0,93$ ,  $p$ -valor  $< 0,001$ ), conforme observado en la Fig. 3.




Fig. 3: Relación entre documentos publicados e índice h

Por lo tanto, los resultados del análisis de correlación indican una tendencia creciente en el número de publicaciones

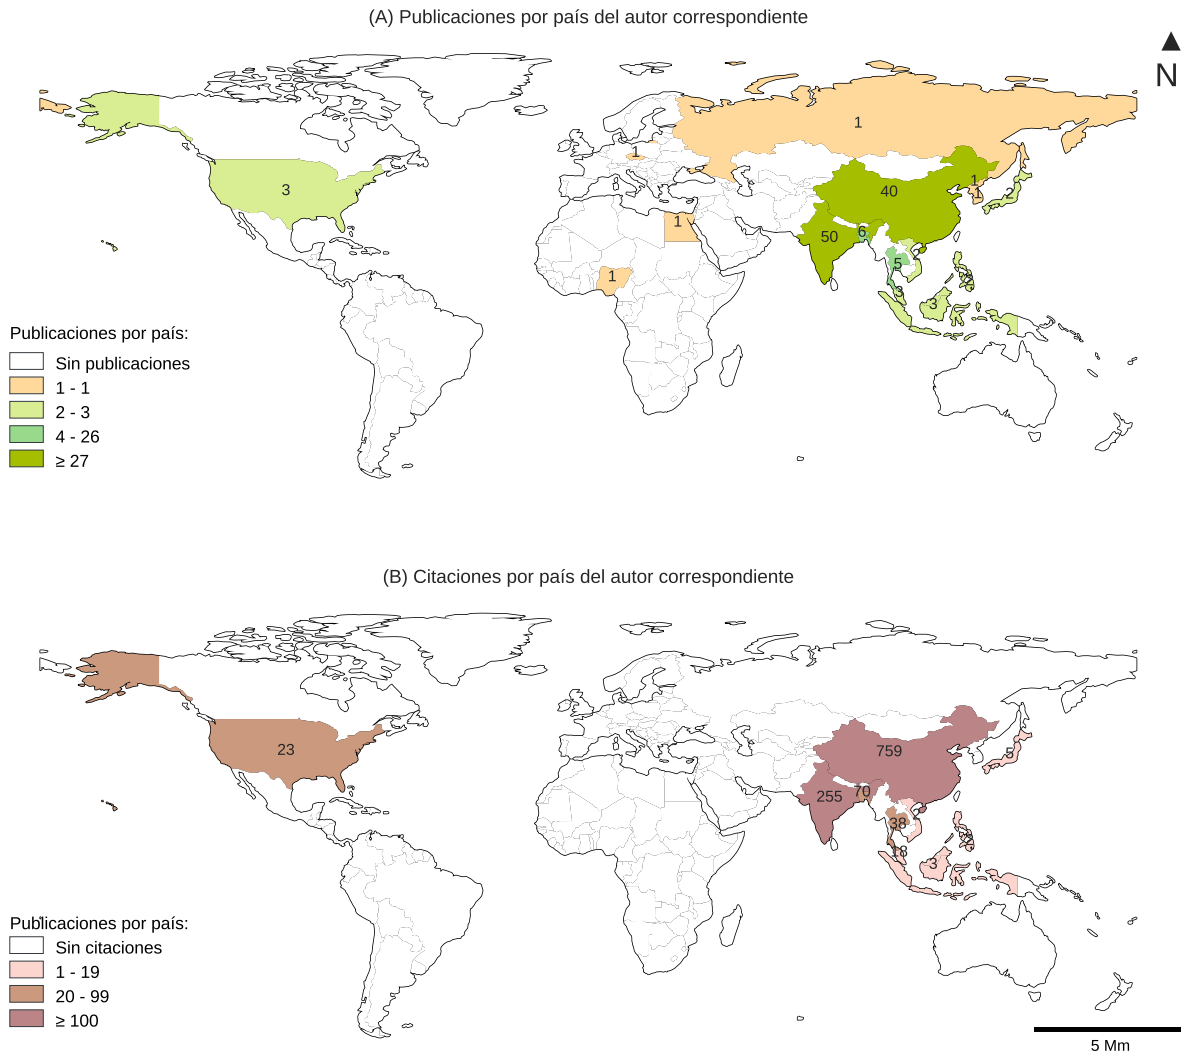


Fig. 4: Publicaciones y citas por país del autor correspondiente

y citas, además se espera que aumente el número de citas de los documentos publicados en los últimos años, dado que aún son investigaciones recientes.

El análisis de la contribución por país ayuda a identificar a los países interesados en estudiar un problema específico, además de medir la influencia de sus investigaciones en la comunidad científica [18]. Con relación a los países interesados en la aplicación de IA en este campo de estudio, se identificaron 15 países con interés de investigación.

La Fig. 4 muestra el número de publicaciones (A) y citas (B) por país del autor correspondiente. En el análisis de correlación mostró una asociación directa significativa ( $r_s = 0.80$ ,  $p\text{-valor} < 0,001$ ) entre la producción total de investigaciones y las citas recibidas por los países.

Los países con mayor aporte según el total de artículos pub-

licados fueron India (50) y China (40), seguidos de Bangladesh (6) y Tailandia (5). Los países de Indonesia, Malasia y Estados Unidos tuvieron tres artículos, seguidos de Japón, Filipinas y Vietnam con dos artículos publicados. Los países con un solo artículo fueron República Checa, Egipto, Corea, Nigeria y Rusia (Fig. 4 A).

Cuando los países fueron evaluados por el número de citas, es decir, por la influencia de sus artículos publicados, se observó que China (759) e India (255) tuvieron el mayor número de citas recibidas (86,29%). El 12,68% de las citas corresponden a investigaciones de Bangladesh (70), Tailandia (38), Estados Unidos (23) y Malasia (18), y el 1,02% restante a los países de Japón (5), Indonesia (3), Filipinas (2) y Vietnam (2). En el caso de los países con un solo artículo publicado, no registraron citas en el periodo analizado (Fig. 4




Fig. 5: Red de colaboración internacional

B).

Además, es importante destacar que el 70% de los artículos publicados son de países pertenecientes al continente asiático, y el 30% restante son de países pertenecientes a los continentes de África, Europa y América. Estos resultados reflejan que el continente asiático no solo es el mayor productor de arroz [2], sino también el de mayor producción científica sobre la integración de IA para la detección de enfermedades en el arroz.

Por otro lado, al evaluar la producción científica basada en la colaboración internacional, se identificó una red de colaboración de 26 países. La Fig. 5 muestra la red de colaboración internacional, generado con VOSviewer, mostrando la conexión de 20 países que aparecieron en dos o más artículos publicados. En la red de colaboración, el tamaño del círculo revela la cantidad de documentos en los que aparece el país, y el color indica el año promedio de publicación de los artículos en los que aparece (entre 2020 y 2022).

Así mismo, además de ser China e India los países con mayor número de artículos publicados y citas recibidas, también son los países con mayor número de colaboración internacional. No obstante, no se observó colaboración entre las investigaciones de los dos países (Fig. 5).

En la Fig. 6 se muestra la red de palabras clave con el fin de analizar e identificar los términos más relevantes utilizados en los artículos analizados. De la misma forma, el tamaño del círculo refleja la cantidad de documentos que contienen la palabra clave y los colores indican un grupo de artículos que están relativamente relacionados entre sí.

El número de palabras clave identificadas en el análisis (336) fue casi tres veces mayor que el número de documentos publicados (Tabla II). Además, la Fig. 6 sólo muestra la conexión de 30 palabras clave que aparecieron en tres o más documentos, es decir, palabras clave que tuvieron una ocurrencia de tres o más veces.

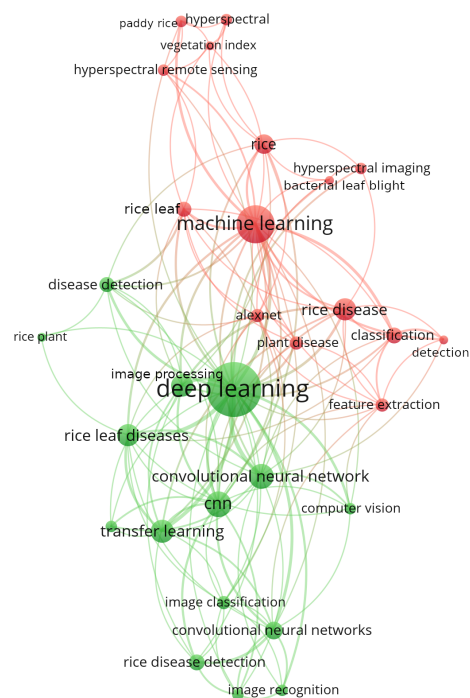


Fig. 6: Red de palabras clave del autor

El análisis de aglomerados permitió identificar dos grupos principales, siendo la palabra clave “*deep learning*” la de mayor ocurrencia, ubicándose en el conglomerado verde, además de estar vinculado con otros términos relevantes como “*convolutional neural network*”, “*computer vision*”, “*transfer learning*”, “*image classification*”, etc. La segunda palabra clave con mayor ocurrencia fue “*machine learning*” y está situada en el conglomerado rojo, con conexiones con otros términos como “*hyperspectral imaging*”, “*alexnet*”, “*feature extraction*”, etc.

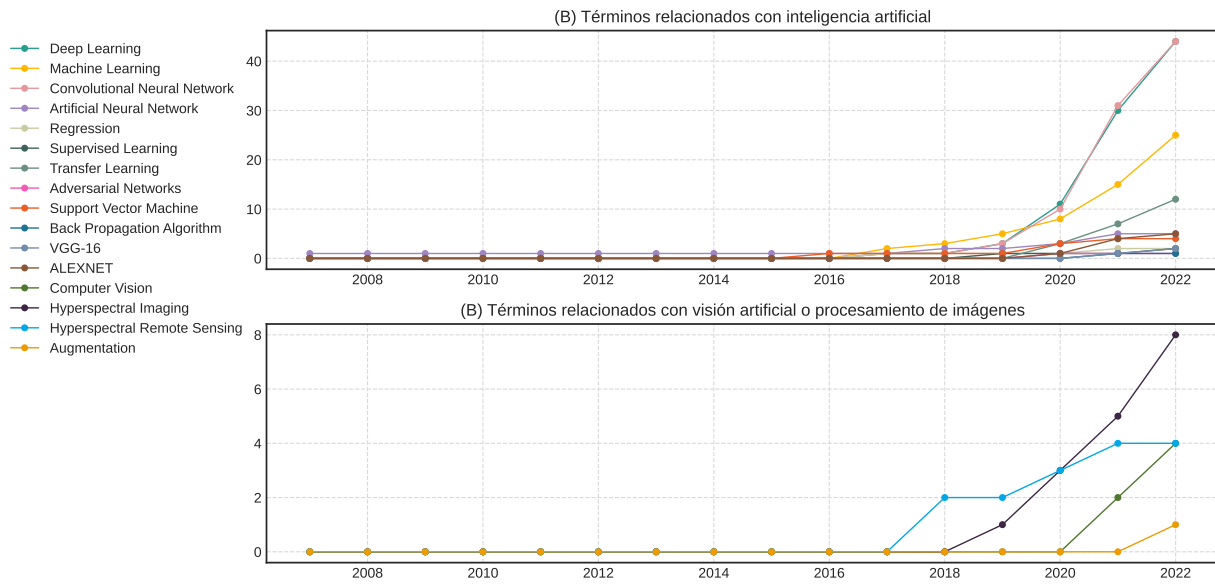


Fig. 7: Palabras clave analizadas de acuerdo a su ocurrencia acumulada anual

Adicionalmente, los términos analizados en la red de ocurrencias (Fig. 6) fueron filtradas por su relación con técnicas o métodos de inteligencia artificial (Fig. 7 A) y por su relación con la visión artificial o procesamiento de imágenes (Fig. 7 B). Los términos considerados fueron analizados de acuerdo a su ocurrencia acumulada anual.

Como se muestra en la Fig. 7 (A), la aplicación de las redes neuronales artificiales (ANN, en inglés *Artificial Neural Network*) inició a partir de 2007, seguido de máquinas de vectores de soporte (SVM, en inglés *Support Vector Machine*), que comenzó a utilizarse desde 2016. Por el contrario, los demás términos relacionados con inteligencia artificial comenzaron a emerger en este campo de estudio a partir de 2017, y presentan una tendencia creciente. Igualmente, la mayoría de los términos relacionados con procesamiento de imágenes o visión artificial tuvieron inicio a partir de 2017, presentando también una tendencia creciente en su aplicación, conforme observado en la Fig. 7 (B).

En consecuencia, los hallazgos muestran que las investigaciones relacionadas con estas palabras clave seguirán aumentando en los próximos años, evidenciando oportunidades para el desarrollo de nuevas investigaciones con métodos aún no explorados.

La Tabla III muestra la lista de los 10 artículos más citados en esta área de investigación ordenados de forma descendente, además de mostrar la información sobre el año y el país de procedencia en el que se realizó la investigación.

El número de citas consideradas en la Tabla III fueron las disponibles hasta agosto de 2022. El 73,79% (867) de las citas del conjunto de metadatos analizado corresponden a los 10 artículos más influyentes, lo que indica que estos documentos contribuyeron significativamente al desarrollo e integración de

TABLA III  
10 ARTÍCULOS MÁS INFLUYENTES EN EL ÁREA

Título	Año	País	Citas
<i>Identification of rice diseases using deep convolutional neural networks</i>	[4] 2017	China	435
<i>Deep feature based rice leaf disease identification using support vector machine</i>	[5] 2020	India	91
<i>Detection of rice plant diseases based on deep transfer learning</i>	[9] 2020	China	60
<i>Image recognition of four rice leaf diseases based on deep learning and support vector machine</i>	[10] 2020	China	53
<i>Rapid Detection of Rice Disease Based on FCM-KM and Faster R-CNN Fusion</i>	[11] 2019	China	53
<i>Rice leaf disease detection using machine learning techniques</i>	[12] 2019	Bangladesh	51
<i>Estimating rice leaf nitrogen concentration: Influence of regression algorithms based on passive and active leaf reflectance</i>	[19] 2017	China	36
<i>Estimation of paddy rice leaf area index using machine learning methods based on hyperspectral data from multi-year experiments</i>	[20] 2018	China	32
<i>Rice blast disease detection and classification using machine learning algorithm</i>	[13] 2018	India	29
<i>Rice Leaf Diseases Classification Using CNN with Transfer Learning</i>	[14] 2020	India	27

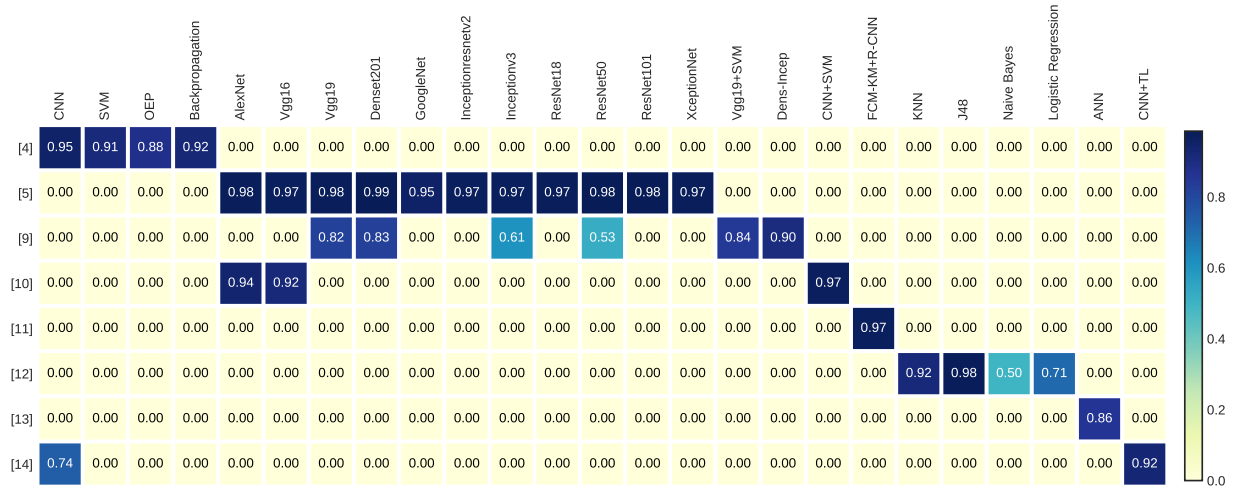


Fig. 8: Técnicas de IA utilizadas y su precisión obtenida

tecnologías de IA para el cultivo del arroz.

Los diez artículos analizados fueron publicados entre 2017 y 2020 (Tabla III), con seis documentos publicados entre 2019-2020 y 335 (28,51%) citas acumuladas [5], [9]–[12], [14]. Cuando se evaluaron los artículos por país del autor correspondiente, seis de los artículos más citados en la lista fueron de China (669 citas) [4], [9]–[11], [19], [20], seguidos de India (147 citas) [5], [13], [14] y Bangladesh (51 citas) [12] con 3 y 1 artículo, respectivamente (Tabla III).

Por otro lado, el análisis también permitió identificar en detalle el objetivo principal de cada artículo, la descripción de la base de datos utilizada, los métodos o técnicas de IA utilizados y la precisión obtenida en los modelos desarrollados.

De este modo, de los diez artículos analizados se identificaron tres temas principales de investigación, siendo el principal tema de interés orientado hacia el desarrollo de modelos de clasificación de enfermedades en cultivos de arroz [4], [5], [9]–[14]. En Lu et al. [4], se utilizó un conjunto de datos de 500 imágenes para detectar diez tipos de enfermedades (Tabla IV), probando las técnicas de redes neuronales convolucionales (CNN, en inglés *Convolutional Neural Network*), SVM, optimización de enjambre de partículas y *backpropagation*, y como resultado el modelo CNN tuvo una precisión del 95% (Fig. 8).

Chen et al. [9] probaron los modelos de Vgg19, Denset201, InceptionV3, ResNet50, Dens-Incep y Vgg19 con SVM (Fig. 8), para detectar 13 tipos de enfermedades del arroz (Tabla IV) con 500 imágenes, donde el modelo Dens-Incep tuvo una precisión del 90%. Sethy et al. [5] obtuvieron una precisión del 99% con el modelo Denset201 (Fig. 8), el cual fue entrenado con 5.932 imágenes para tratar de identificar cuatro tipos de enfermedades (Tabla IV). Del mismo modo, en Jiang et al. [10] se identificaron 4 tipos de enfermedades del arroz, con un modelo basado en CNN y SVM, con una precisión del 95%, que fue entrenado con un conjunto de datos de 8.911

imágenes, conforme mostrado en la Fig. 8 y Tabla IV.

TABLA IV  
LISTA DE ENFERMEDADES DEL ARROZ ANALIZADAS

Enfermedades	[4]	[5]	[9]	[10]	[11]	[12]	[13]	[14]
Blast	✓	✓	✓	✓	✓		✓	✓
False smut	✓							
Brown spot	✓	✓	✓			✓		✓
Bakanae	✓							
Sheath blight	✓		✓	✓	✓			✓
Sheath rot	✓							
Bacterial blight	✓	✓		✓	✓	✓		
Bacterial sheath	✓		✓					
brown rot								
Seeding blight	✓							
Bacterial wilt	✓							
Tungro		✓						
Stackburn			✓					
Leaf smut			✓			✓		
Leaf scald			✓					
White tip			✓					
Bacterial leaf streak			✓					
Stem rot			✓					
Sheath spot			✓					
Grain spotting and peck			✓					
Kernel smut			✓					
Stripe blight				✓				

En Zhou et al. [11] se combinó la red de propuestas de regiones y CNN (R-CNN) con el algoritmo de agrupamiento *K-Means* (FCM-KM), para identificar tres tipos de enfermedades en cultivos de arroz (Fig. 8), dando como resultado un modelo con una precisión del 97% (Tabla IV), que fue entrenado y

probado con 3.010 imágenes recolectadas, como presentado en la Tabla IV y Fig. 8.

Un conjunto de datos con 120 imágenes fueron utilizados en el trabajo de Ahmed et al. [12], para probar las técnicas de k-vecino más cercano (KNN = 92%, en inglés *k-nearest neighbour*), árbol de decisión (J48 = 98%), naive bayes (50%) y regresión logística (71%), para identificar tres tipos de enfermedades de arroz. En [13] se utilizó las ANN para detectar la enfermedad de *blast* en los cultivos de arroz (Tabla IV), con una precisión del 90% (Fig. 8), con 300 imágenes. Por último, Ghosal y Sarkar [14] utilizaron un conjunto de datos de 1.649 imágenes, y combinaron el modelo de CNN con el método de transferencia del aprendizaje para identificar las enfermedades de arroz de *blast*, *brown spot* y *sheath blight* (Fig. 8), con una precisión del 92%.

Finalmente, los otros temas tratados en los artículos analizados de la Tabla III estuvieron orientados a la estimación de la concentración de nitrógeno en las hojas de arroz [19], y la estimación del índice de área foliar en cultivos de arroz [20].

#### IV. CONCLUSIONES

Este estudio presentó un análisis de las publicaciones donde IA fue aplicada para detectar enfermedades del arroz. De este modo, fueron analizados 122 documentos entre 2007-2022 (hasta agosto), con la finalidad de identificar el estado actual y tendencia de las investigaciones, la identificación de los países interesados, la tendencia de los temas, así como también las investigaciones más representativas en este campo de estudio. En este contexto, los resultados mostraron que en la literatura aún existen pocos trabajos publicados sobre integración de IA para la detección de enfermedades en cultivos de arroz. Sin embargo, en el análisis del estado actual de las investigaciones se observó la presencia de una tendencia creciente tanto en el número de publicaciones como también en el número de citas, principalmente desde 2016. Referente a los países con mayor número de investigaciones, se identificó que el 70% de los artículos publicados pertenecen a autores principales del continente asiático, principalmente los países con mayor número de publicaciones y citas fueron China e India. Los temas identificados con el análisis de las palabras claves mostró que el interés principal de las publicaciones en este campo de estudio está orientado especialmente al desarrollo de modelos de clasificación utilizando métodos de inteligencia artificial como *machine learning* y *deep learning*. Asimismo, con el análisis de las investigaciones más representativas, fue observado que en los últimos años también ha aumentado el interés por la aplicación de diferentes y nuevas técnicas de IA, no obstante, hasta la fecha, las técnicas más utilizadas fueron ANN, CNN y SVM. Finalmente, es importante resaltar que existe oportunidad para nuevas investigaciones, aplicando métodos o técnicas aún no explorados, así como también hay oportunidad de investigaciones futuras para países que aún no han explorado estas tecnologías.

#### AGRADECIMIENTOS

El presente trabajo fue realizado con el apoyo de la Coordinación de Perfeccionamiento del Personal de Educación Superior - Brasil (CAPES) - Código de Financiamiento 001, y parcialmente por el Consejo Nacional de Desarrollo Científico y Tecnológico - Brasil (CNPq), código de financiamiento CNPq-304197/2021-1; CNPq-303090/2021-9.

#### REFERENCIAS

- [1] W.E.F., "This is how much rice is produced around the world and the countries that grow the most," World Economic Forum, Mar. 09, 2022. [Online]. Available: <https://www.weforum.org/agenda/2022/03/visualizing-the-world-s-biggest-rice-producers/>.
- [2] C. Marina, "Value of Wholegrain Rice in a Healthy Human Nutrition," *Agriculture*, vol. 11(8), pp. 720, 2021.
- [3] F.A.O., "La agricultura mundial en la perspectiva del año 2050," Food and Agriculture Organization of the United Nations, Rome, Oct. 13, 2009. [Online]. Available: [https://www.fao.org/fileadmin/templates/wsf/docs/Issues\\_papers/Issues\\_papers\\_SP/La\\_agricultura\\_mundial.pdf](https://www.fao.org/fileadmin/templates/wsf/docs/Issues_papers/Issues_papers_SP/La_agricultura_mundial.pdf).
- [4] Y. Lu, S. Yi, N. Zeng, Y. Liu, Y. Zhang, "Identification of rice diseases using deep convolutional neural networks," *Neurocomputing*, vol. 267, pp. 378–384, 2017.
- [5] P.K. Sethy, N.K. Barpanda, A.K. Rath, S.K. Behera, "Deep feature based rice leaf disease identification using support vector machine," *Computers and Electronics in Agriculture*, vol. 175, pp. 105527, 2020.
- [6] P.A. Seck, A. Diagne, S. Mohanty, M. Wopereis, "Crops that feed the world 7: Rice," *Food security*, vol. 4(1), pp. 7–24, 2012.
- [7] U.N., "Transforming our world: the 2030 Agenda for Sustainable Development," United Nations, Dec. 30, 2015. [Online]. Available: [https://www.un.org/ga/search/view\\_doc.asp?symbol=A/70/L.1&Lang=E](https://www.un.org/ga/search/view_doc.asp?symbol=A/70/L.1&Lang=E).
- [8] D. Kub, C. Bin, L. Zhengyue, D. Yan, W. Hailong, "A characterization of rice pests and quantification of yield losses in the japonica rice zone of Yunnan, China," *Crop Protection*, vol.29(6), pp. 603–611, 2010.
- [9] J. Chen, D. Zhang, Y.A. Nanekaran, D. Li, "Detection of rice plant diseases based on deep transfer learning," *Journal of the Science of Food and Agriculture*, vol. 100(7), pp. 3246–3256, 2020.
- [10] F. Jiang, Y. Lu, Y. Chen, D. Cai, G. Li, "Image recognition of four rice leaf diseases based on deep learning and support vector machine," *Computers and Electronics in Agriculture*, vol. 179, pp. 105824, 2020.
- [11] G. Zhou, W. Zhang, A. Chen, M. He, X. Ma, "Rapid Detection of Rice Disease Based on FCM-KM and Faster R-CNN Fusion," *IEEE Access*, vol. 7, pp. 143190–143206, 2019.
- [12] K. Ahmed, T.R. Shahidi, S.M. Irfanul Alam, S. Momen, "Rice leaf disease detection using machine learning techniques," 2019 International Conference on Sustainable Technologies for Industry 4.0, STI 2019, 2019.
- [13] S. Ramesh, D. Vydeki, "Rice blast disease detection and classification using machine learning algorithm," *Proceedings - 2nd International Conference on Micro-Electronics and Telecommunication Engineering, ICMETE 2018*, vol. 8742850, pp. 255–259, April 2018.
- [14] S. Ghosal, K. Sarkar, "Rice Leaf Diseases Classification Using CNN with Transfer Learning," 2020 IEEE Calcutta Conference, CALCON 2020 - Proceedings, vol. 9106423, pp. 230–236, 2020.
- [15] I. Zupic, T. Cater, "Bibliometric Methods in Management and Organization," *Organ Res Methods*, vol. 18(3), pp. 429–472, 2015.
- [16] M. Aria, C. Cuccurullo, "An R-tool for comprehensive science mapping analysis," *J Informetr*, vol. 11(4), pp. 959–975, 2017.
- [17] O.B. Onyancha, "Open Research Data in Sub-Saharan Africa: A Bibliometric Study Using the Data Citation Index," *Pub Res Q*, vol. 32, pp. 227–246, 2016.
- [18] E.Y.A. Rodríguez, E.C.A. Rodríguez, A.F. Silva, P.M.R. Rizol, R.C. Miranda, F.A.S. Marins (in press); "Analysis of Machine Learning integration into Supply Chain Management," *Int J Logist Syst Manag*, 2021.
- [19] J. Sun, J. Yang, S. Shi, B. Chen, L. Du, W. Gong, S. Song, "Estimating rice leaf nitrogen concentration: Influence of regression algorithms based on passive and active leaf reflectance," *Remote Sensing*, vol. 9(9), pp. 951, 2017.



- [20] L. Wang, Q. Chang, J. Yang, X. Zhang, F. Li, "Estimation of paddy rice leaf area index using machine learning methods based on hyperspectral data from multi-year experiments," PLoS ONE, vol. 13(12), pp. e0207624, 2018.