

Contribuciones del aprendizaje automático en el descubrimiento del dengue: un análisis cuantitativo

Contributions of Machine Learning in The Discovery of Dengue: A
Quantitative Analysis

Wilson Arrubla-Hoyos^{1*} <https://orcid.org/0000-0001-7119-7603>

Andrés Solano- Barliza² <https://orcid.org/0000-0003-4244-3750>

¹Universidad Nacional Abierta y a Distancia. Sincelejo, Colombia.

²Universidad de La Guajira, Riohacha. La Guajira, Colombia.

*Autor para la correspondencia: wilson.arrubla@unad.edu.co

RESUMEN

El dengue es una enfermedad vírica que cobra vidas humanas año tras año, lo que genera la necesidad de explorar nuevas soluciones desde la informática para lograr una detección temprana y eficaz. Este estudio tuvo como objetivo identificar las tendencias de investigación que vinculan las técnicas de aprendizaje automático (*machine learning*) con el dengue. Para este fin, se realizó un análisis cuantitativo y sistemático, que comenzó con una búsqueda de aprendizaje automático y dengue en Scopus sin restricciones temporales. Se hallaron 377 documentos publicados entre 2010 y 2022. Posteriormente, se aplicó la técnica PRISMA y se filtraron los documentos a partir de los criterios de inclusión y exclusión para asegurar la calidad del análisis. Mediante el empleo de herramientas como *R Studio*, la biblioteca *biblioshiny* de *bibliometrix* y VOSviewer se examinaron los elementos clave de la producción científica como: países, autores destacados, revistas relevantes y co-ocurrencias de palabras clave. Los resultados permitieron identificar tres áreas de enfoque: diagnóstico del dengue, pronóstico del dengue y control de mosquitos. Se encontró que la investigación en el uso del aprendizaje automático para detectar el dengue ha crecido de manera

constante y ha atraído a más investigadores a partir de 2016. Las técnicas de aprendizaje automático más utilizadas son: *Artificial Neural Network* (ANN), *Decision Tree*, *Support Vector Machine* (SVM) y una tendencia a usar *Deep learning*. Por su parte, el área del diagnóstico utiliza variables meteorológicas como humedad, temperatura y lluvias para realizar los pronósticos de los brotes del dengue.

Palabras clave: machine learning; dengue; diagnóstico; pronóstico; variables meteorológicas.

ABSTRACT

Dengue is a viral disease that claims human lives year after year, generating the need to explore new computer-based solutions to achieve early and effective detection. This study aimed to identify research trends that link machine learning techniques to dengue. To this end, a scientometric and systematic analysis was performed, starting with a search for machine learning and dengue in Scopus without temporal restrictions. Three hundred seventy-seven documents were found that were published from 2010 to 2022. Subsequently, PRISMA technique was applied and the documents were filtered based on the inclusion and exclusion criteria to ensure the quality of the analysis. Using tools such as R Studio, biblioshiny library of bibliometrix and VOSviewer, the key elements of scientific production were examined such as: countries, notable authors, relevant journals and keyword co-occurrences. The results identified three focus areas: dengue diagnosis, dengue prognosis, and mosquito control. Research on using machine learning to detect dengue was found to have grown steadily and attracted more researchers as of 2016. The most commonly used machine learning techniques are: Artificial Neural Network (ANN), Decision Tree, Support Vector Machine (SVM) and a trend to use Deep learning. On the other hand, the diagnosis area uses meteorological variables such as humidity, temperature and rainfall to make forecasts of dengue outbreaks.

Keywords: machine learning; dengue; diagnosis; forecast; meteorological variables.

Recibido: 08/08/2023

Aceptado: 20/02/2024

Introducción

El dengue (DENV) es una enfermedad vírica transmitida principalmente por el mosquito de la especie *Aedes aegypti* y *Aedes albopictus*, presente con mayor frecuencia en las zonas tropicales y subtropicales.⁽¹⁾ Se estima una carga anual de entre 50 y 100 millones de pacientes en los hospitales.⁽²⁾ Esta enfermedad tiene cuatro serotipos conocidos como DEN1, DEN2, DEN3 y DEN 4 y existe la posibilidad de infección de cada uno de ellos.⁽³⁾ El DENV presenta una serie de signos y síntomas clínicos que pueden ir desde una fiebre leve hasta un síndrome de *shock* en un dengue grave (DG) que puede causar la muerte de las personas.⁽⁴⁾

Existen algunas variables meteorológicas que pueden influir en la proliferación del DENV como las lluvias, la temperatura y la humedad.⁽⁵⁾ Algunos estudios han correlacionado las lluvias e inundaciones con la reproducción de los mosquitos de la familia *Aedes*,⁽⁶⁾ la temperatura con tasa de reproducción⁽⁷⁾ y la humedad con la longevidad del mosquito y la replicación del virus.^(8,9)

Según la Organización mundial de la Salud la distribución mundial del DENV se estima en 390 millones de infectados anualmente, lo que lo convierte en una carga económica para los países que la padecen.⁽¹⁰⁾ Por su parte, la Organización Panamericana de la Salud (OPS) en el informe epidemiológico de 2019 para la región de las Américas registró más de 2,7 millones de casos, que incluyen 22 127 casos de dengue grave (DG) y 1206 muertes.⁽¹¹⁾

Frente a la situación que se vive por la proliferación del DENV de manera endémica muchos investigadores han realizado diferentes estudios utilizando técnicas estadísticas y de *machine learning* (ML) para mitigar el impacto que este genera. Tales estudios tienen diferentes enfoques, algunos para pronosticar los brotes relacionando factores meteorológicos que permitan anticiparse a las autoridades competentes para controlar los brotes^(12,13) y otros se enfocan en el diagnóstico clínico como apoyo a los trabajadores de la salud.^(14,15)

Teniendo en cuenta lo mencionado, se hace necesario identificar las tendencias actuales de las investigaciones que relacionan las técnicas del *machine learning* con la enfermedad DENV que sirvan como punto de partida para nuevas investigaciones que pretendan trabajar con técnicas del *machine learning* para predecir o pronosticar la enfermedad. En consecuencia, este estudio tuvo como fin identificar las tendencias actuales concernientes a investigaciones que involucran técnicas de *machine learning* y la enfermedad del DENV y responder las siguientes preguntas de investigación:

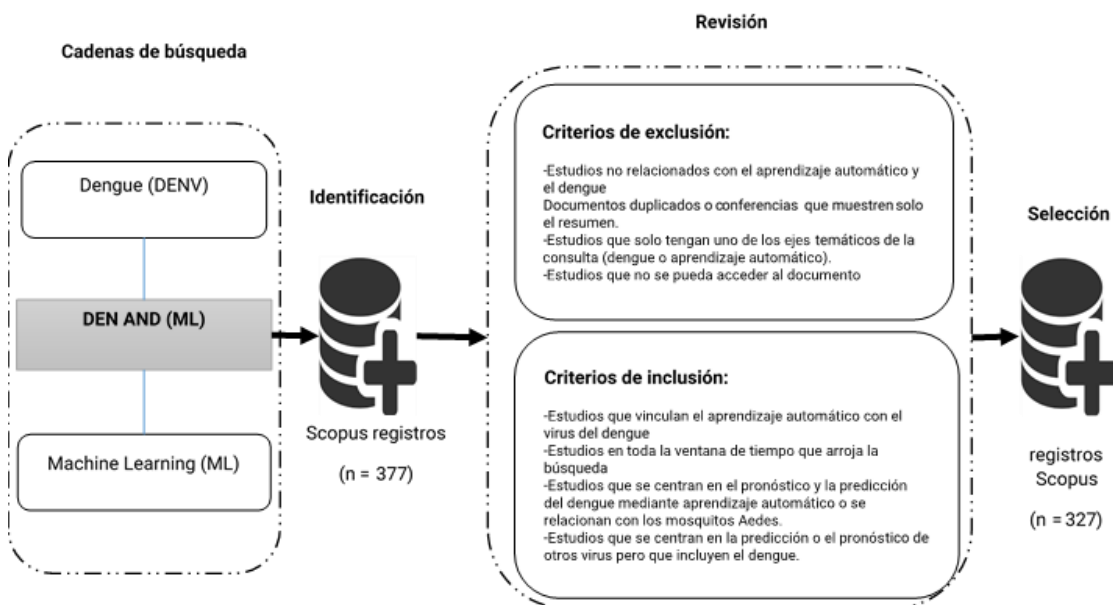
- ¿Cuáles son las tendencias de investigación científica asociadas al uso de técnicas del *machine learning* para predecir el DENV?
- ¿Cómo ha sido la evolución de los artículos publicados en los últimos años?
- ¿Cuáles son las revistas, artículos y países con mayor influencia en el tema analizado?

Para dar respuesta a estos interrogantes se realizó un análisis cuantitativo basado en 377 artículos científicos, producto de usar la cadena de búsqueda que relaciona los ejes centrales del tema analizado (ML y DENV). Los resultados se limitan a la base de datos Scopus, que es la herramienta de búsqueda de contenidos científicos que tiene la mayor colección de trabajos actualizados con alta calidad. La metodología aplicada tiene su sustento en la importancia que reciben los análisis cuantitativos hoy día por la comunidad científica.^(16,17)

El objetivo de este artículo radica en la identificación de las tendencias de investigación que vinculan las técnicas de aprendizaje automático (*machine learning*, ML) con la enfermedad del dengue (DENV) a través de un análisis sistemático y cuantitativo. Con el fin de lograr dicho objetivo general se han establecido los siguientes objetivos específicos: primero, discernir la producción científica relacionada con ML y DENV; segundo, categorizar dicha producción científica de acuerdo con su enfoque y, tercero, clasificar los descubrimientos principales con el propósito de establecer las tendencias dominantes en la investigación en torno a la temática que guía este estudio.

Métodos

El estudio bibliométrico se realizó utilizando las palabras clave de los dos ejes temáticos que componen el tema analizado, como se muestra en la figura 1. Para ello se especificó la cadena de búsqueda (TITLE-ABS-KEY (“machine learning”) AND TITLE-ABS-KEY (dengue)), que se ingresó a la base de datos especializada Scopus. La selección de la base de datos se realiza bajo dos principios, primero porque es la herramienta de búsqueda que contiene la mayor cantidad de trabajos a nivel mundial de resúmenes, referencias y trabajos científicos; segundo, porque las herramientas tecnológicas que permiten hacer este tipo de estudio limitan su alcance a este tipo de bases de datos.



Fuente: Elaboración propia.

Fig. 1 – Esquema metodológico de la búsqueda en Scopus.

El análisis se realizó con la ventana cronológica del 2010 hasta 2022; se recopilan los 377 artículos que se obtuvieron como resultado de la búsqueda. No se limitaron palabras clave para obtener la mayor cantidad de documentos. Sin embargo, la producción científica en esta base de datos se limita a esta cantidad.

En octubre de 2022 se ejecutó la búsqueda y el análisis bibliométrico utilizando las herramientas *Bibliometrix* y *R studio* que permiten hacer un mapeo completo de la producción científica. Además, se utilizó la herramienta VOSviewer para completar

el análisis y se insertaron visualizaciones de redes bibliométricas basadas en relaciones de citación, concitaciones y acoplamiento bibliográfico.


Para realizar un estudio riguroso y de calidad se utilizó la metodología PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) que permite garantizar la integridad de la investigación. Para ello se establecieron los criterios de inclusión y exclusión, como se evidencia en la figura 1; se aplicaron a los resultados generales de la búsqueda inicial y se obtuvieron 327 documentos para realizar el análisis cientiométrico y de co-citaciones.

Resultados

Análisis bibliométrico

Este análisis parte de 327 documentos científicos publicados entre 2010 y 2021; la producción científica en estos años se puede evidenciar en la figura 2. Se identificaron 174 artículos (53,2 %), 11 capítulos de libro (3,4 %), 111 artículos de conferencia (33,9 %), tres resúmenes de conferencia (0,9 %), 22 *review* (6,7 %), cinco documentos editoriales (1,5 %) y un *data paper* (0,3 %). En la creación de estos documentos científicos participaron 1338 autores; 11 documentos se realizaron por un solo autor (3,4 %); el índice de coautores por documento es de 4,92 y el 31,19 % se ha realizado en coautoría internacional. Además, el promedio de citas por documento es 7,48; la tasa de crecimiento anual es del 42,4 % y se han referenciado 14 304 documentos.

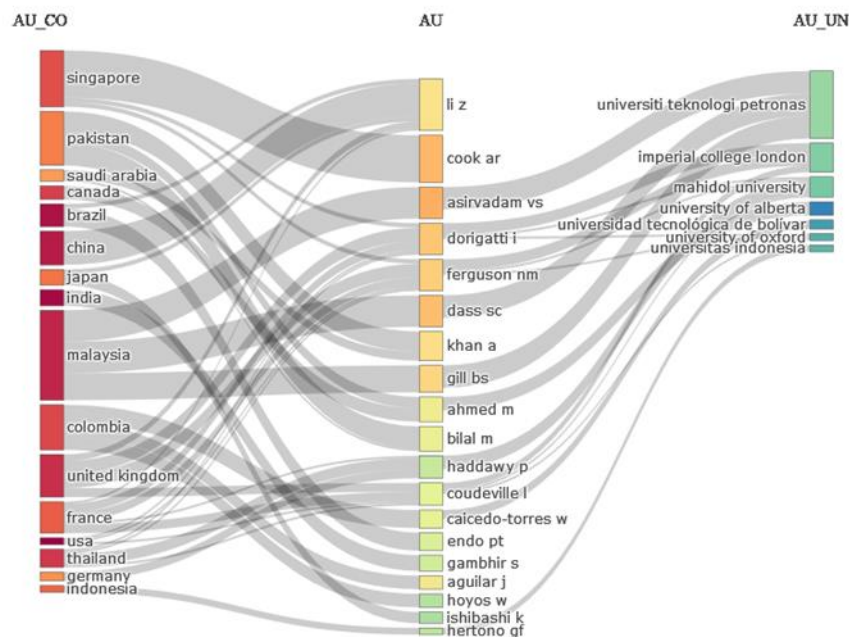
En la figura 2 se puede evidenciar un crecimiento significativo de la producción científica concerniente al uso de técnicas de ML con la enfermedad tropical del DENV entre los años 2016 y 2021.



Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 2 – Producción científica anual de investigaciones relacionadas con *machine learning* y dengue.

La figura 3 relaciona los países, autores y universidades con mayor producción científica a nivel mundial. Se puede observar que el país con mayor producción es Malasia (12,2 %), seguido de Singapur (7,6 %), Pakistán (7,3 %) y Colombia (6,11 %). Por otra parte, se identifican los 20 autores más relevantes en el tema; se encontró, en primer lugar, a Li con contribuciones en países como China, Brasil y Reino Unido; seguido de la producción de Cook Ar que únicamente ha realizado investigaciones en Singapore. Además, se identifican las siete universidades con mayor participación, encabezada por la *Universiti Teknologi Petronas* de Malasia. Aunque se relacionan los países, autores y universidades con mayor participación en investigaciones relacionadas con el dengue y el *machine learning*, se puede percibir la necesidad de mejorar la contribución entre países, autores y universidades.

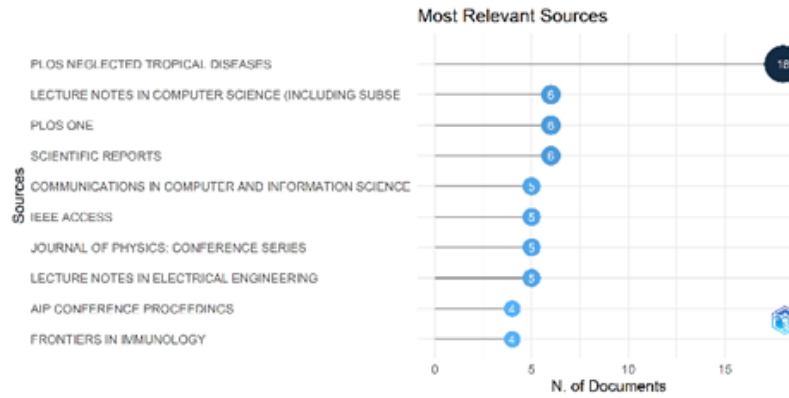


Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 3 – Producción científica por país, autor y universidades a nivel mundial.

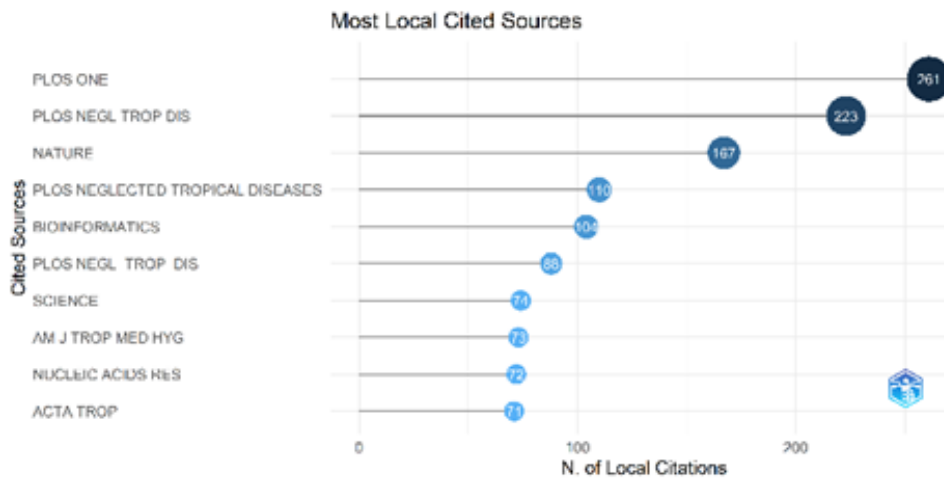
Revistas y compilación de eventos más importantes

En cuanto a las revistas más relevantes se evidencia el top 10 en la figura 4, donde *Plos Neglected Tropical Diseases* lidera por mayoría de documentos publicados (18); sin embargo, la figura 5 presenta información de las revistas que tienen mayor impacto en la comunidad científica, toda vez que el indicador se muestra por citaciones (*from Reference Lists*); es decir, que estas revistas podrían tener mayor calidad en sus productos y son mayoritariamente utilizados por los investigadores. El top 10 de las revistas por citaciones la lidera *Plos One* con 261 citas, seguido por *Plos Negl Trop Dis* con 223.



Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 4 – Revistas más relevantes.



Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 5 – Revistas con mayor impacto en citaciones.

La tabla 1 complementa este análisis de revistas, organizando de mayor a menor por el índice H que evalúa la producción científica de la revista. Además, se presentan los índices G y M.

Tabla 1 - Indicadores de las revistas con mayor relevancia

Revistas	H_index	G_index	M_index
<i>Plos Neglected Tropical Diseases</i>	7	15	1,167
<i>Plos One</i>	5	5	1,000
<i>Scientific Reports</i>	5	6	1,000
<i>Ieee Access</i>	4	4	0,800
<i>Acta Tropica</i>	3	3	0,600

<i>Bmc Infectious Diseases</i>	3	3	0,600
<i>Communications in Computer and Information Science</i>	2	3	0,333
<i>Elife</i>	2	2	0,667
<i>Frontiers In Genetics</i>	2	2	0,667
<i>Frontiers In Immunology</i>	2	3	0,500

Fuente: Elaboración propia.

Análisis de productividad por autores

La tabla 2 presenta a los 10 autores más productivos en el tema de estudio de esta revisión. El número máximo de artículos es cinco y los tres primeros autores que muestra la tabla tienen la misma cantidad de publicaciones. Sin embargo, en la tabla se tiene en cuenta el criterio artículos fraccionario, que hace énfasis en las ponderaciones asignadas, si fue autor principal o autor secundario. En ese orden de ideas el autor más relevante es Asirvadam con cinco artículos y un nivel de 1,28 artículo fraccionario, seguido de Cook y Dass.


Tabla 2 - Autores con mayor productividad

Autor	Artículos	Artículos fraccionados
Asirvadam VS	5	1,28
Cook AR	5	0,76
Dass SC	5	1,28
Dorigatti I	4	0,71
Ferguson NM	4	0,71
Gill BS	4	0,95
Khan A	4	0,65
Li Z	4	0,54
Na NA	4	4,00
Aguilar J	3	1,00

Fuente: Elaboración propia.

La productividad de los autores respecto al tiempo se puede apreciar en la figura 6. Se evidencia que Cook y Khan son los investigadores que han sido constantes en investigaciones que se relacionan con la temática analizada, con publicaciones

en los años 2016, 2018, 2020 y 2022. Esta información es relevante porque permite observar la constancia y permanencia de los aportes de los autores en el tema de estudio y también los que actualmente están trabajando en el tema. Esta información puede ser de utilidad para elaborar el estado de arte de un proyecto que trabaje la temática de estudio.



Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 6 – Producción científica de autores más relevantes respecto al tiempo.

Por otro lado, la producción científica se mide por *Scimago Journal y ranking* de países SJR a través de diferentes indicadores. Uno de los más relevantes es el índice h que cuantifica la producción científica.^(18,19,20) La tabla 3 presenta los autores con mayor relevancia y se puede identificar el índice h de los autores. Asimismo, se evidencia el índice g que cuantifica la productividad bibliométrica basada en el historial de publicaciones⁽²¹⁾ y el índice m que mide el impacto anual en el área científica del investigador.⁽²²⁾ Además, presenta el total de citas TC, el total de publicaciones y el año que inició el trabajo sobre el tema.

Tabla 3 - Indicadores de los autores con mayor relevancia

Autor	h_index	g_index	m_index	TC	NP	PY_start
Cook AR	4	4	0,571	138	4	2016
Khan A	4	4	0,571	136	4	2016
Li Z	4	4	0,667	220	4	2017

Bilal M	3	3	0,429	111	3	2016
Caicedo-Torres W	3	3	0,429	17	3	2016
Dorigatti I	3	4	0,600	40	4	2018
Ferguson NM	3	4	0,600	40	4	2018
Khan S	3	3	0,429	111	3	2016
Ng LC	3	3	0,429	123	3	2016
Abril M	2	2	0,333	57	2	2017

Fuente: Elaboración propia.

Tendencias de investigación

La revisión de los documentos permite identificar tres grandes áreas de trabajo como se identifica en la tabla 4. La primera se enfoca al apoyo para el diagnóstico de la enfermedad; algunos autores utilizan variables como signos, síntomas y exámenes de laboratorio para predecir el DENV. La segunda área está enfocada al pronóstico de brotes del dengue, muchas veces utilizando series de tiempo y técnicas de ML que permiten hacer regresiones. Finalmente, se identifican algunos trabajos enfocados en el control de mosquitos desde la clasificación por imágenes.

Tabla 4 - Áreas de estudio y técnicas de ML utilizadas

Área de estudio	Descripción	Técnicas utilizadas	Referencias
Diagnóstico del dengue	Las investigaciones se enfocan al apoyo diagnóstico de la enfermedad. La clasificación tiene en cuenta variables como signos, síntomas y resultados de laboratorio; en algunas investigaciones se utilizan biomarcadores a nivel molecular para predecir la enfermedad	ANN	(23,24,25,26,27)
		SVM	(25,28,27,29,30)
		<i>Decision Tree</i>	(23,31,32,33,34)
		<i>Deep Learning</i>	(35,36,37,31,38)
Pronóstico del dengue	Se enfoca a predecir brotes del dengue teniendo en cuenta variables	<i>Decision Tree</i>	(39,40,41,42)

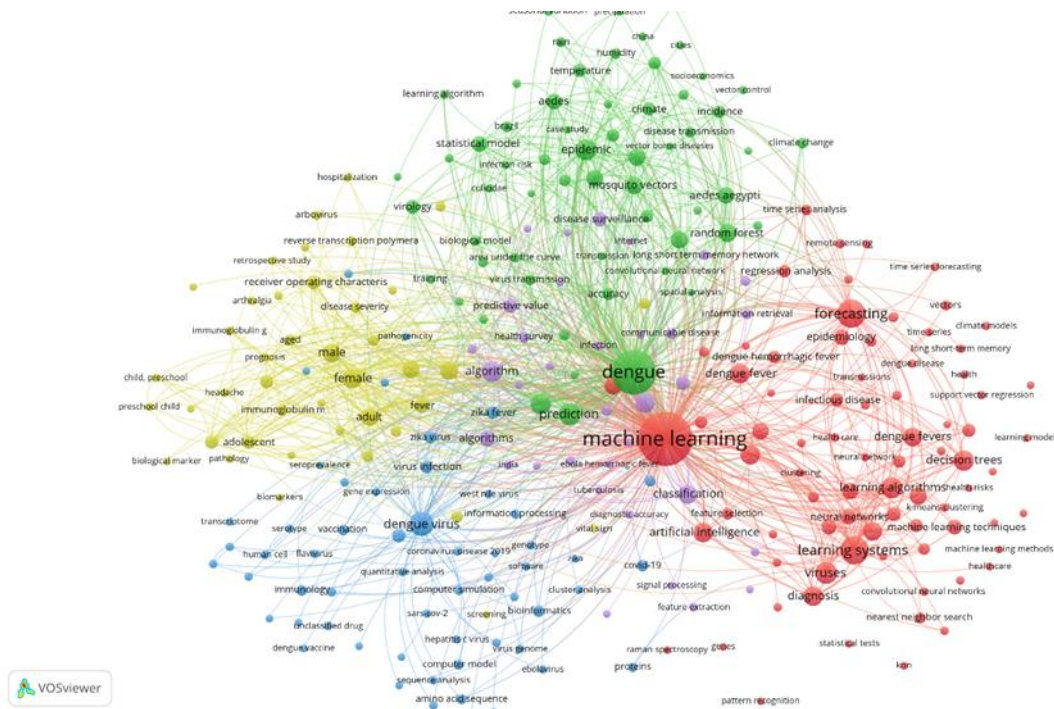
	climatológicas como la temperatura la humedad entre otras. también utilizan imágenes de satélite para predecir la incidencia	<i>Time Series</i> <i>Random Forest</i> SVM	(43,44,45,39,46) (47,48,49,50,51) (52,53,54,55,56)
Control de mosquitos	Su enfoque está orientado a la clasificación de la especie de mosquitos y sexo para realizar control epidemiológico.	CNN SVM <i>Partial least squares (PLS)</i>	(57,58) (59) (60)

Fuente: Elaboración propia.

Acoplamiento bibliográfico

El acoplamiento bibliográfico permite agrupar los artículos científicos de un área específica, lo que facilita la recuperación de la información que se produce y consume en la comunidad científica de manera visual.^(61,62) En la figura 7 se presenta la co-ocurrencia de las palabras clave, agrupados en cinco clústeres los términos por su frecuencia. El clúster rojo relaciona términos enfocados al ML, sistemas de aprendizaje, *forecasting*, diagnóstico y se identifican algunas técnicas de *machine learning*. El clúster verde destaca la enfermedad del DENV como eje central; aglutina términos como predicción, mosquito vector, *Aedes aegypti* y algunas variables climáticas asociadas al pronóstico, como la humedad y la temperatura. El clúster morado relaciona conceptos de algoritmos, clasificación, valores predictivos, regresiones. El clúster amarillo relaciona, mayoritariamente, variables que se utilizan para el diagnóstico de la enfermedad como: sexo, edad, fiebre, hospitalización, dolor de cabeza, inmunoglobulina g y m, que son relevantes para el diagnóstico clínico del DENV. Finalmente, el clúster azul relaciona términos asociados al virus del DENV y otras enfermedades con síntomas similares como

Zika, COVID-19, hepatitis, chikunguña y algunas variables a nivel de biomarcadores y genes del virus.



Fuente: Elaboración propia, generada desde bibliometrix.

Fig. 7 – Producción científica de autores más relevantes respecto al tiempo.

Discusión

Esta investigación presenta un análisis bibliométrico que busca identificar las tendencias de investigación asociadas al uso de las técnicas de *machine learning* en la predicción del DENV. Aunque se han realizado algunos trabajos similares no se ha tenido en cuenta identificar áreas de estudios generales en los que se está trabajando el *machine learning* para predecir el dengue o controlar la enfermedad. Este estudio persigue generar un aporte desde la perspectiva mencionada anteriormente, analizar la evolución de la producción científica e identificar los actores con mayor relevancia en el tema analizado que permita a otros investigadores conocer hacia donde pueden orientar sus trabajos. Los resultados obtenidos en esta investigación presentan tres áreas de acción: una enfocada al diagnóstico del dengue, que busca apoyar al personal médico en la

toma de decisiones oportunas; otra dirigida a la predicción de los brotes de dengue en función del apoyo epidemiológico.

Hasta este punto los resultados coinciden con el estudio de Hoyos y otros⁽⁶³⁾ que aunque identifica desafíos y trabajos futuros en el modelado del DENV, al mostrar las técnicas más utilizadas en el diagnóstico y el pronóstico (enfoque epidémico), no se relaciona el área de control de mosquitos desde la clasificación de la especie. Desde el punto de vista de las técnicas utilizadas este estudio difiere con estos autores,⁽⁶³⁾ al encontrar que en el diagnóstico del dengue las técnicas más utilizadas son: *Neural Artificial Neural Network* (ANN), Árboles de decisiones (lo que coincide con lo hallado por Sylvestre⁽⁶⁴⁾), *Support vector machine* (SVM) y la tendencia que viene creciendo del *Deep Learning*. En el área del pronóstico la tendencia es hacia las técnicas Series de tiempo, Árboles de decisiones, Bosques aleatorios (*Random Forest* RF) y SVM. Finalmente, en el área de control de mosquitos se encuentra que las técnicas de ML más utilizadas son *Convolutional Neural Network* (CNN), *Support Vector Machine* (SVM) y *Partial Least Squares* (PLS). Otros estudios similares se enfocaron en encontrar tendencias solamente en métodos actuales para los brotes de DENV⁽⁶⁵⁾ y la predicción de enfermedades infecciosas, que es un eje más amplio que el objeto de esta revisión.⁽⁶⁶⁾

Existe un crecimiento lineal de las investigaciones sobre el tema analizado desde 2016 hasta 2021. Los países del continente asiático son los que mayor trabajo vienen realizando en esta temática (Malasia 12,2 %, seguido de Singapur 7,6 % y Pakistán 7,3 %). La tendencia se puede correlacionar con la carga mundial del dengue que, según la Organización Mundial de la Salud, el 70 % se concentra en este continente. Los autores más relevantes encontrados en los documentos son LI Zhichao de la *Tsinghua University Beijing*, China y Alex R. Cook de la *University of Singapore*. La universidad con mayores trabajos es la *Universiti Teknologi Petronas* en Malasia. Estos hallazgos reafirman lo mencionado.

Respecto a las revistas con mayor impacto se identifican las 10 principales que pueden orientar a los investigadores para presentar sus trabajos y tener un mayor alcance en la comunidad científica.

Conclusiones

Se concluye que existen tres áreas de actuación en el que se utilizan técnicas del *machine learning* para predecir el dengue. Las áreas más trabajadas son la del diagnóstico que tiene en cuenta variables de signos, síntomas, exámenes de laboratorio para determinar la presencia de la enfermedad. También en esta área se logra observar una tendencia del uso de biomarcadores de la enfermedad y expresiones genéticas del virus para predecir, incluso, su gravedad.

Las técnicas de ML más utilizadas son: ANN, *Decision Tree*, SVM y una tendencia de usar *Deep learning*. Por su parte, el área del diagnóstico utiliza variables meteorológicas como la humedad, temperatura y lluvias para realizar los pronósticos de los brotes del dengue. Las técnicas más utilizadas son *Time Series*, *Decisión Tree*, *Random Forest* y SVM. Finalmente, el área control de mosquitos se enfoca en la clasificación de la especie de mosquitos y el sexo para realizar control epidemiológico.

Por otro lado, se puede concluir que el continente asiático lidera en producción científica, destacándose países como Malasia, seguido de Singapur y Pakistán. Los autores más prominentes son Li Zhichao, de China, y Alex R. Cook, de Singapur. Además, la Universidad que más contribuye en este campo es la *Universiti Teknologi Petronas*, en Malasia. Respecto a la divulgación científica, Estados Unidos tiene mayor impacto con las revistas de la corporación PLOS tanto en producción como en impacto por citación.

Referencias bibliográficas

1. Rosen L, Shroyer DA, Tesh RB, Freier JE, Lien JC. Transovarial transmission of dengue viruses by mosquitoes: *Aedes albopictus* and *Aedes aegypti*. *The American Journal of Tropical Medicine and Hygiene*. 1983;32(5):1108-19.
2. Dey SK, Rahman MdM, Howlader A, Siddiqi UR, Uddin KMM, Borhan R, *et al.* Prediction of dengue incidents using hospitalized patients, metrological and socio-economic data in Bangladesh: A machine learning approach. Bhattacherjee D, editor. *PLOS ONE*. 2022;17(7):e0270933, DOI: <https://doi.org/10.1371/journal.pone.0270933>

3. WHO. Dengue y dengue grave. 2021 [acceso 03/10/2021]. Disponible en: <https://www.who.int/es/news-room/fact-sheets/detail/dengue-and-severe-dengue>
4. Guo P, Liu T, Zhang Q, Wang L, Xiao J, Zhang Q, *et al.* Developing a dengue forecast model using machine learning: A case study in China. Althouse B, editor. PLOS Neglected Tropical Diseases. 2017;16;11(10):e0005973. DOI: <https://doi.org/10.1371/journal.pntd.0005973>
5. Carvajal TM, Viacruz KM, Hernández LFT, Ho HT, Amalin DM, Watanabe K. Machine learning methods reveal the temporal pattern of dengue incidence using meteorological factors in metropolitan Manila, Philippines. BMC Infectious Diseases. 2018;18(1):183. DOI: <https://doi.org/10.1186/s12879-018-3066-0>
6. Lindsay M, Mackenzie J. Vector-borne viral diseases and climate change in the Australasian region: Major concerns and the public health response. En: Curson P, Guest C, Jackson E, editors. The UWA Profiles and Research Repository: Australian Medical Association and Greenpeace International. 1997 [acceso 20/10/2023]:47-62. Disponible en: <https://research-repository.uwa.edu.au/en/publications/vector-borne-viral-diseases-and-climate-change-in-the-australasia>
7. Gratz NG. Emerging and resurging vector-borne diseases. Annual Review of Entomology. 1999;44(1):51-75.
8. Hales S, de Wet N, Maindonald J, Woodward A. Potential effect of population and climate changes on global distribution of dengue fever: an empirical model. The Lancet. 2002;360(9336):830-4. DOI: [https://doi.org/10.1016/S0140-6736\(02\)09964-6](https://doi.org/10.1016/S0140-6736(02)09964-6)
9. Mellor PS, Leake CJ. Climatic and geographic influences on arboviral infections and vectors. Revue Scientifique et Technique-Office International des Epizooties. 2000 [acceso 20/07/2023];19(1):41-60. Disponible en: <https://acortar.link/4dS2FW>
10. Fredericks AC, Fernández-Sesma A. The burden of dengue and chikungunya worldwide: implications for the southern United States and California. Annals of global health. 2014;80(6):466-75. DOI: <https://doi.org/10.1016/j.aogh.2015.02.00>
11. OPS. Actualización Epidemiológica Dengue, chikunguña y Zika en el contexto de COVID-19 23 de diciembre de 2021. 2021 [acceso 30/03/2022]. Disponible en:

https://iris.paho.org/bitstream/handle/10665.2/55639/EpiUpdate23Dec2021_spa.pdf?sequence=2&isAllowed=y

12. Salami D, Sousa CA, Martins M do RO, Capinha C. Predicting dengue importation into Europe, using machine learning and model-agnostic methods. *Scientific Reports*. 2020 [acceso 20/07/2023]16;10(1). Disponible en: <https://www.nature.com/articles/s41598-020-66650-1>

13. Nguyen VH, Tuyet-Hanh TT, Mulhall J, Minh HV, Duong TQ, Chien NV, *et al*. Deep learning models for forecasting dengue fever based on climate data in Vietnam. Kamel MG, editor. *PLOS Neglected Tropical Diseases*. 2022 13;16(6):e0010509. DOI: <https://doi.org/10.1371/journal.pntd.0010509>

14. Gambhir S, Malik SK, Kumar Y. PSO-ANN based diagnostic model for the early detection of dengue disease. *New Horizons in Translational Medicine*. 2017;4(1):1-8. DOI: <https://doi.org/10.1016/j.nhtm.2017.10.001>

15. Hoyos W, Aguilar J, Toro M. A clinical decision-support system for dengue based on fuzzy cognitive maps. *Health Care Manag Sci*. 2022;(16). DOI: <https://doi.org/10.1007/s10729-022-09611-6>

16. León-Gómez A, Ruiz-Palomo D, Fernández-Gámez MA, García-Revilla MR. Sustainable tourism development and economic growth: Bibliometric review and analysis. *Sustainability*. 2021;13(4):2270. DOI: <https://doi.org/10.3390/su13042270>

17. Santos-Jaén JM, León-Gómez A, Serrano-Madrid J. The Effect of Corporate Social Responsibility on Earnings Management: Bibliometric Review. *International Journal of Financial Studies*. 2021;9(4):68. DOI: <https://doi.org/10.3390/ijfs9040068>

18. SJR. SJR-Help. 2022 [acceso 24/06/2023]. Disponible en: https://www.scimagojr.com/help.php#understand_countries

19. Hirsch JE. Ha: An index to quantify an individual's scientific leadership. *Scientometrics*. 2019 [acceso 20/07/2023]5;118(2):673-86. Disponible en: <https://link.springer.com/article/10.1007/s11192-018-2994-1>

20. Hirsch JE. An index to quantify an individual's scientific research output. *Proceedings of the National Academy of Sciences*. 2005;102(46):16569-72. Disponible en: <https://www.pnas.org/content/102/46/16569?pagewanted=all>

21. ULPGC. Indicadores e índices de la producción científica | Biblioteca ULPGC. 2022 [acceso 24/07/2023]. Disponible en: https://biblioteca.ulpgc.es/factor_impacto(https://biblioteca.ulpgc.es/factor_impacto)
22. Pérez. Los índice h y m. 2009 [acceso 24/06/2023]. Disponible en: <https://grupodih.info/lp.html>(<https://grupodih.info/lp.html>)
23. Gambhir S, Malik SK, Kumar Y. The diagnosis of dengue disease: An evaluation of three machine learning approaches. IGI Global. En: I. Management Association (Ed.). Cognitive Analytics: Concepts, Methodologies, Tools, and Applications. 2020:1076-95. DOI: <https://doi.org/10.4018/978-1-7998-2460-2.ch055>
24. Davi C, Pastor A, Oliveira T, Neto FB d L, Braga-Neto U, Bigham AW, *et al*. Severe Dengue Prognosis Using Human Genome Data and Machine Learning. IEEE Transactions on Biomedical Engineering. 2019;66(10):2861-8. DOI: <https://doi.org/10.1109/TBME.2019.2897285>
25. Mello-Román JD, Mello-Román JC, Gómez-Guerrero S, García-Torres M. Predictive Models for the Medical Diagnosis of Dengue: A Case Study in Paraguay. Computational and Mathematical Methods in Medicine. 2019:1-7. DOI: <https://doi.org/10.1155/2019/7307803>
26. Jayampathi KTK, Jananjaya MAC, Fernando EPC, Liyanage YA, Pemadasa MGNM, Gunarathne GWDA. Mobile Medical Assistant and Analytical System for Dengue Patients. En: ICAC 2021-3rd International Conference on Advancements in Computing, Proceedings. 2021. DOI: <https://doi.org/10.1109/ICAC54203.2021.9671097>
27. Sultana Z, Nahar L, Basnin N, Hossain MS. Inference and Learning Methodology of Belief Rule Based Expert System to Assess Chikungunya. Communications in Computer and Information Science. 2021. En: Mahmud M, Kaiser MS, Kasabov N, Iftekharruddin K, Zhong N. (eds) Applied Intelligence and Informatics. All 2021. Communications in Computer and Information Science. 2021;1435. Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-82269-9_1
28. Singh KD. Particle Swarm Optimization assisted Support Vector Machine based Diagnostic System for Dengue prediction at the early stage. En: Proceedings-2021 3rd International Conference on Advances in Computing, Communication Control

and Networking, ICAC3N 2021:844-8. DOI:

<https://doi.org/10.1109/ICAC3N53548.2021.9725670>

29. Mariappan V, Adikari S, Shanmugam L, Easow JM, Balakrishna Pillai A. Expression dynamics of vascular endothelial markers: endoglin and syndecan-1 in predicting dengue disease outcome. *Translational Research*. 2021;232:121-41.

DOI: <https://doi.org/10.1016/j.trsl.2021.02.001>

30. Hamdani H, Hatta HR, Puspitasari N, Septiarini A, Henderi. Dengue classification method using support vector machines and cross-validation techniques. *IAES International Journal of Artificial Intelligence*. 2022;11(3):1119-29. DOI:

<https://doi.org/10.11591/ijai.v11.i3.pp1119-1129>

31. Sajid A, Awan MA. Monitoring, Tracking and Diagnosing Dengue Fever using Smartphone, GPS and Machine Learning. En *ICET 2021-16th International Conference on Emerging Technologies 2021, Proceedings*. 2021. DOI:

<https://doi.org/10.1109/ICET54505.2021.9689785>

32. Boruah AN, Biswas SK, Baishya P, Ealapollu DC. Expert System for Dengue Fever Prediction (ESDFP). En: *2021 IEEE 2nd International Conference on Technology, Engineering, Management for Societal Impact using Marketing, Entrepreneurship and Talent, TEMSMET 2021*. 2021. DOI:

<https://doi.org/10.1109/TEMSMET53515.2021.9768723>

33. Abdualgalil B, Abraham S, Ismael WM. Early Diagnosis for Dengue Disease Prediction Using Efficient Machine Learning Techniques Based on Clinical Data. *Journal of Robotics and Control (JRC)*. 2022;3(3):257-68. DOI:

<https://doi.org/10.18196/jrc.v3i3.14387>

34. Caicedo-Torres W, Paternina-Caicedo Á, Pinzón-Redondo H, Gutiérrez J. Differential diagnosis of dengue and chikungunya in Colombian children using machine learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2018;11238

LNAI:181-192. DOI: https://doi.org/10.1007/978-3-030-03928-8_15

35. Mishra S, Dash A, Jena L. Use of deep learning for disease detection and diagnosis. *Studies in Computational Intelligence*. 2021;903:181-201. DOI:

https://doi.org/10.1007/978-981-15-5495-7_10

36. Hafqat S, Fayyaz M, Khattak HA, Bilal M, Khan S, Ishtiaq O, *et al.* Leveraging Deep Learning for Designing Healthcare Analytics Heuristic for Diagnostics. Neural Processing Letters. 2021 DOI: <https://doi.org/10.1007/s11063-021-10425-w>
37. Shukla A, Goyal V. Deep Learning-Based Severe Dengue Prognosis Using Human Genome Data with Novel Feature Selection Method. Advances in Intelligent Systems and Computing. 2021;1158:473-82. DOI: https://doi.org/10.1007/978-981-15-4409-5_43
38. Neto S, Tabosa T, Salomão Teixeira I, Rocha S, Vanderson, *et al.* Machine learning and deep learning techniques to support clinical diagnosis of arboviral diseases: A systematic review. PLoS Neglected Tropical Diseases. 2022;16(1). DOI: <https://doi.org/10.1371/JOURNAL.PNTD.0010061>
39. Ismail S, Fildes R, Ahmad R, Wan Mohamad Ali WN, Omar T. The practicality of Malaysia dengue outbreak forecasting model as an early warning system. Infectious Disease Modelling. 2022;7(3):510-25. DOI: <https://doi.org/10.1016/j.idm.2022.07.008>
40. Cordeiro da Silva CC, Lans de Lima C, Gomes da Silva AC, Machado Magalhaes G, Musah A, Aldosery A, *et al.* Spatiotemporal forecasting for dengue, chikungunya fever and Zika using machine learning and artificial expert committees based on meta-heuristics. Research on Biomedical Engineering. 2022;38(2):499-537. DOI: <https://doi.org/10.1007/s42600-022-00202-6>
41. Aleixo R, Kon F, Rocha R, Camargo MS, De Camargo RY. Predicting Dengue Outbreaks with Explainable Machine Learning. En: Proceedings-22nd IEEE/ACM International Symposium on Cluster, Cloud and Internet Computing, CCGrid 2022. 2022:940-47. DOI: <https://doi.org/10.1109/CCGrid54584.2022.00114>
42. Dhaka A, Singh P. Comparative analysis of epidemic alert system using machine learning for dengue and chikungunya. En Proceedings of the Confluence 2020-10th International Conference on Cloud Computing, Data Science and Engineering. 2020:798-804. DOI: <https://doi.org/10.1109/Confluence47617.2020.9058048>
43. Patil S, Pandya S. Forecasting Dengue Hotspots Associated with Variation in Meteorological Parameters Using Regression and Time Series Models. Frontiers in Public Health. 2021. DOI: <https://doi.org/10.3389/fpubh.2021.798034>

44. Benedum CM, Shea KM, Jenkins HE, Kim LY, Makuzon N. Weekly dengue forecasts in Iquitos, Peru; San Juan, Puerto Rico; and Singapore. *PLoS Neglected Tropical Diseases*. 2020;14(10):1-26. DOI: <https://doi.org/10.1371/journal.pntd.0008710>
45. Bogado JV, Stalder DH, Schaerer CE, Gómez-Guerrero S. Time Series Clustering to Improve Dengue Cases Forecasting with Deep Learning. En *Proceedings-2021 47th Latin American Computing Conference, CLEI 2021*. 2021. DOI: <https://doi.org/10.1109/CLEI53233.2021.9640130>
46. Singh G, Soman B. Spatiotemporal epidemiology and forecasting of dengue in the state of Punjab, India: Study protocol. *Spatial and Spatio-temporal Epidemiology*. 2021;39:100444. DOI: <https://doi.org/10.1016/j.sste.2021.100444>
47. Indhumathi K, Kumar KS. Seasonal Infectious Disease Prediction based on Electronic Patient Health Records using Boosted Random Forest Algorithms. En: *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering, ICACITE 2022*:2025-2032. DOI: <https://doi.org/10.1109/ICACITE53722.2022.9823453>
48. Rahman MS, Pientong C, Zafar S, Ekalaksananan T, Paul RE, Haque U, *et al*. Mapping the spatial distribution of the dengue vector *Aedes aegypti* and predicting its abundance in northeastern Thailand using machine-learning approach. *One Health*. 2021. DOI: <https://doi.org/10.1016/j.onehlt.2021.100358>
49. Zhao N, Charland K, Carabali M, Nsoesie EO, Maheu-Giroux M, Rees E, *et al*. Machine learning and dengue forecasting: Comparing random forests and artificial neural networks for predicting dengue burden at national and sub-national scales in Colombia. *PLoS Neglected Tropical Diseases*. 2020;14(9):1-16. DOI: <https://doi.org/10.1371/journal.pntd.0008056>
50. Mussumeci E, Codeço Coelho F. Large-scale multivariate forecasting models for Dengue-LSTM versus random forest regression. *Spatial and Spatio-temporal Epidemiology*. 2020. DOI: <https://doi.org/10.1016/j.sste.2020.100372>
51. Sarma D, Hossain S, Mitra T, Bhuiya MAM, Saha I, Chakma R. Dengue Prediction using Machine Learning Algorithms. En: *IEEE Region 10 Humanitarian Technology Conference, R10-HTC, 2020*. 2020-December. DOI: <https://doi.org/10.1109/R10-HTC49770.2020.9357035>

52. Kapoor R, Ahuja S, Kadyan V. Machine Learning based Classification Algorithm for Classification of Dengue (Dengue Fever -DF, Dengue Harmonic Fever -DHF & Serve Dengue -SD). En: ECS Transactions, 2022;107(1):4659-73. DOI: <https://doi.org/10.1149/10701.4659ecst>
53. Babu DS, Raju B, Swapna S, Kolluri J, Ramesh D, Bonagiri R. Dengue symptoms classification analysis with improved conditional probability decision analysis. Applied Nanoscience. 2022. DOI: <https://doi.org/10.1007/s13204-022-02387-9>
54. Mustaffa Z, Sulaiman MH, Ernawan F, Yusof Y, Mohsin MFM. Dengue outbreak prediction: Hybrid meta-heuristic model. En: Proceedings-2018 IEEE/ACIS 19th International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing, SNPD 2018. 2018:271-4. DOI: <https://doi.org/10.1109/SNPD.2018.8441095>
55. Abeyrathna KD, Granmo OC, Zhang X, Goodwin M. Adaptive Continuous Feature Binarization for Tsetlin Machines Applied to Forecasting Dengue Incidences in the Philippines. En: 2020 IEEE Symposium Series on Computational Intelligence, SSCI 2020. 2020:2084-92. DOI: <https://doi.org/10.1109/SSCI47803.2020.9308291>
56. Dey L, Mukhopadhyay A. A Classification-based Approach to Prediction of Dengue Virus and Human Protein-Protein Interactions using Amino Acid Composition and Conjoint Triad Features. En: Proceedings of 2019 IEEE Region 10 Symposium, TENSYPMP 2019. 2019:373-8. DOI: <https://doi.org/10.1109/TENSYPMP46218.2019.8971382>
57. Yang Q, Chung J, Robinson KL, Schmidt TL, Ross PA, Liang J, *et al.* Sex-specific distribution and classification of Wolbachia infections and mitochondrial DNA haplogroups in *Aedes albopictus* from the Indo-Pacific. PLoS Neglected Tropical Diseases. 2022;16(4). DOI: <https://doi.org/10.1371/journal.pntd.0010139>
58. Yin MS, Haddawy P, Ziemer T, Wetjen F, Supratak A, Chiamsakul K, *et al.* A deep learning-based pipeline for mosquito detection and classification from wingbeat sounds. Multimedia Tools and Applications, 2022;82:5189-5205. DOI: <https://doi.org/10.1007/s11042-022-13367-0>
59. Rakotonirina A, Caruzzo C, Ballan V, Kainiu M, Marin M, Colot J, *et al.* Wolbachia detection in *Aedes aegypti* using MALDI-TOF MS coupled to artificial intelligence. Scientific Reports, 2021;11(1). DOI: <https://doi.org/10.1038/s41598-021-00888-1>

60. Lambert B, Sikulu-Lord MT, Mayagaya VS, Devine G, Dowell F, Churcher TS. Monitoring the Age of Mosquito Populations Using Near-Infrared Spectroscopy. *Scientific Reports*, 2018;8(1). DOI: <https://doi.org/10.1038/s41598-018-22712-z>
61. Boeris CE. Aplicación de métodos bibliométricos a la evaluación de colecciones: El caso de la Biblioteca del Instituto Argentino de Radioastronomía. [Tesis de grado]. Universidad Nacional de La Plata, Facultad de Humanidades Y Ciencias de la Educación. 2000 [acceso 24/06/2023]. p. 80 Disponible en: <https://www.memoria.fahce.unlp.edu.ar/tesis/te.371/te.371.pdf>
62. Martínez N, Carabel T, García S. Review of scientific research in ISO 9001 and ISO 14001: A bibliometric analysis. *Cuadernos de Gestión*. 2021 [acceso 24/06/2023];21(1):29-45. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=7746411>
63. Hoyos W, Aguilar J, Toro M. Dengue models based on machine learning techniques: A systematic literature review. *Artificial Intelligence in Medicine*. 2021;119:102157. DOI: <https://doi.org/10.1016/j.artmed.2021.102157>
64. Sylvestre E, Joachim C, Cécilia-Joseph E, Bouzillé G, Campillo-Gimenez B, Cuggia M, *et al.* Data-driven methods for dengue prediction and surveillance using real-world and Big Data: A systematic review. *PLoS Neglected Tropical Diseases*. 2022;16(1). DOI: <https://doi.org/10.1371/journal.pntd.0010056>
65. Balakumar M, Vontela HR, Shinde VV, Kulshrestha V, Mishra B, Aduri R. Dengue outbreak and severity prediction: current methods and the future scope. *Virus Disease*. 2022;33(2):125-31. DOI: <https://doi.org/10.1007/s13337-022-00767-x>
66. Keshavamurthy R, Dixon S, Pazdernik KT, Charles LE. Predicting infectious disease for biopreparedness and response: A systematic review of machine learning and deep learning approaches. *One Health*. 2022;15:100439. DOI: <https://doi.org/10.1016/j.onehlt.2022.100439>

Conflicto de intereses

Los autores declaran que no tienen conflicto de intereses.

Contribuciones de los autores

Conceptualización: Wilson Arrubla-Hoyos, Andrés Solano-Barliza.

Análisis formal: Wilson Arrubla-Hoyos.

Investigación: Wilson Arrubla-Hoyos, Andrés Solano-Barliza.

Metodología: Wilson Arrubla-Hoyos, Andrés Solano-Barliza.

Validación: Wilson Arrubla-Hoyos, Andrés Solano-Barliza.

Redacción – borrador original: Wilson Arrubla-Hoyos y Andrés Solano-Barliza.

Redacción – revisión y edición: Wilson Arrubla-Hoyos y Andrés Solano-Barliza.