



Sistemas para la selección de cultivos, una revisión sistemática de la literatura

Recommendation systems for crop selection, a systematic review of literature

Juan Jair Avendaño-Sánchez^{1*}, Omar Alba-Hernández¹, Rodrigo Rodríguez-Franco¹, María Angélica-Cerdán¹

¹Tecnológico Nacional de México/ ITS de Xalapa, Av. Del Tecnológico S/N, colonia Santa Bárbara, ciudad de Xalapa, Veracruz., C.P. 91098, Xalapa, Veracruz

*Autor de correspondencia: 217002546@itsx.edu.mx

Recibido 04 de julio 2022; recibido en forma revisada 11 de octubre 2022; aceptado 30 de octubre 2022

RESUMEN

Las técnicas de inteligencia artificial son utilizadas en la Agricultura de Precisión (AP) para aumentar la producción y mejorar el rendimiento de los cultivos. Esto permite a los agricultores optimizar el uso de los recursos, disminuir el impacto ambiental y facilitar la toma de decisiones. En la actualidad, aumentar la producción y el rendimiento de los cultivos es de vital importancia para alcanzar la soberanía alimentaria de todas las regiones del mundo. Es por esto, que se propone el desarrollo de un algoritmo que recomiende la raza de maíz nativo que mejor se adapte a las propiedades del suelo y condiciones climáticas presentes en la región montañosa central del estado de Veracruz. Para lograrlo, se realizó una revisión sistemática de la literatura con la finalidad

conocer las características en común que presentan los diferentes “sistemas recomendadores de cultivos” que se han desarrollado en los últimos años (2017-2022), así como identificar los métodos y/o técnicas, los parámetros y las herramientas tecnológicas de desarrollo utilizadas en estos sistemas para generar las recomendaciones.

Los resultados demuestran que la técnica más utilizada en los sistemas recomendadores de cultivos son los algoritmos de Machine Learning, siendo las Redes Neuronales Artificiales el método más usado. Los parámetros más considerados son el pH, el nitrógeno, el fósforo, el potasio y la temperatura. En general, los sistemas revisados tienen una precisión que va del 82% al 99.91%. En conclusión los sistemas de recomendación de cultivos cuentan con una estructura básica definida, sin embargo, el principal problema para el sistema propuesto, es el acceso y recopilación de la información necesaria para lograr la adecuada clasificación de las razas de maíz nativo de la región, por lo que la técnica a utilizar debe consistir en un Sistema Experto, alimentado por el conocimiento de una persona experta en este grano básico.

Palabras Clave: Inteligencia Artificial; Algoritmo; Sistema de Soporte a Decisiones; Sistema Experto; Suelo; Rendimiento.

ABSTRACT

Artificial intelligence techniques are used in Precision Agriculture (PA) to increase production and improve crops. This allows farmers to optimize the use of resources, reduce environmental impact and facilitate decision making. At present, increasing the production and yeild of crops is of vital importance to achieve food sovereignty of all regions of the world. This is why the development of an algorithm that recommends the breed of native corn that best suits soil properties and climatic conditions present in the central mountain region of the state of Veracruz is proposed. To achieve this, a systematic review of literature was carried out in order to know the common characteristics presented by the different “crop recommender systems” that have been developed in

recent years (2017-2022), as well as identify the methods and// o Techniques, parameters and technological development tools used in these systems to generate recommendations. The results show that the most used technique in crop recommender systems are Machine Learning algorithms, the most used method being artificial neural networks. The most considered parameters are pH, nitrogen, phosphorus, potassium and temperature. In general, revised systems have a precision that goes from 82% to 99.91%. In conclusion, crop recommendation systems have a defined basic structure, however, the main problem for the proposed system is the access and collection of the necessary information to achieve the proper classification of the native corn breeds of the region, So the technique to be used must consist of an expert system, fed by the knowledge of an expert person in this basic grain.

Keywords: Artificial Intelligence; Algorithm; Decision Support Systems; Expert System; Soil; Yield.

INTRODUCCIÓN

La agricultura es una actividad que ha acompañado al hombre desde hace miles de años, las técnicas y conocimientos utilizados han evolucionado con el paso del tiempo. Hoy en día, la agricultura se integra con las TIC's (Tecnologías de la Información y la Comunicación) para conformar la agricultura de precisión y lograr mejorar el rendimiento de cultivos, optimizar el uso de los recursos, disminuir el impacto ambiental y facilitar la toma de decisiones estratégicas y económicas. Esto permite desarrollar procesos agrícolas más eficientes, confiables, modernos y seguros en comparación con los métodos tradicionales utilizados por la mayoría de agricultores en países en desarrollo. Sin embargo, la integración de la tecnología y las técnicas de la agricultura no se pueden dar de manera inmediata, ya que podrían ocasionar problemas de adaptación y un alto costo de inversión a los productores. Por estas razones, una solución viable para ayudar a los mismos, es el diseño de sistemas de recomendación de cultivos, que les ayude a decidir el cultivo que mejor convenga en base a las condiciones climáticas

y las propiedades del suelo con las que dispone el agricultor. La selección del cultivo, es la más importante al momento de sembrar, ya que determina en gran medida el grado de producción, el tiempo necesario hasta el momento de la cosecha y las posibles ganancias que se obtendrán de la misma. La presente revisión sistemática de la literatura se hace con el fin de conocer: las características comunes que presentan los Sistemas de Recomendación de Cultivos; las técnicas y/o métodos principalmente utilizados; los parámetros de entrada considerados; las diferentes métricas de validación de los sistemas y las herramientas tecnológicas utilizadas para su desarrollo. Esto con el objetivo de desarrollar un algoritmo recomendador de maíces nativos en la región montañosa del Estado de Veracruz, en base a las propiedades del suelo, condiciones climáticas y la finalidad de uso del agricultor. Esto pretende ayudar a la conservación de las razas de maíz nativo y asegurar la soberanía alimentaria de la región.

MATERIALES Y MÉTODOS

La metodología utilizada para realizar esta revisión sistemática de la literatura fue la propuesta por Kitchenham (2004), el procedimiento para realizarla consiste en cinco pasos: 1) Definir las preguntas de investigación; 2) Realizar la búsqueda literaria; 3) Seleccionar estudios; 4) Clasificar artículos y extraer y 5) Realizar la agregación de datos.

1) Definir las preguntas de investigación

La revisión está centrada en reconocer las características en común de los sistemas recomendadores de cultivos, las técnicas o métodos que utilizan, los parámetros considerados para generar la recomendación, las métricas de validación y las herramientas de desarrollo. A partir de esto, se definieron cuatro preguntas principales de investigación y quince subpreguntas que complementan las primeras, la tabla 1 muestra las preguntas de investigación realizadas.

Tabla 1 Preguntas de investigación.

<p>1. ¿Cómo se integra el Sistema Recomendador?</p>	<p>¿Para qué cultivo(s) se aplica el sistema? ¿Cuál es la finalidad del sistema? ¿De dónde se adquiere la información? ¿A quién va dirigido?</p>
--	---

<p>2. ¿Qué métodos y técnicas utilizan los sistemas de recomendación?</p>	<p>¿Qué método o técnica se utiliza para generar la recomendación? ¿Qué variables utiliza para hacer la recomendación? ¿Qué herramientas fueron utilizadas para su desarrollo? ¿Cómo se presenta la salida del sistema?</p>
<p>3. ¿Cómo se valida el sistema?</p>	<p>¿Cuál es el tamaño de la muestra utilizada? ¿Cuál fue la prueba o diseño experimental que realizaron? ¿Cuál fue la métrica utilizada para su validación? ¿Dónde fue evaluado? ¿Cuáles fueron sus resultados?</p>
<p>4. ¿Qué aporta a mi trabajo?</p>	<p>¿Qué hicieron los autores? ¿Cómo podría serme de utilidad?</p>

2) Realizar la búsqueda literaria

Una vez definidas las preguntas de investigación se seleccionaron las bases de datos y las palabras clave necesarias para generar las cadenas de búsqueda.

Bases de Datos: [SciELO](#), [IEEEExplore](#), [ACM](#), [Springer](#), [ScienceDirect](#) y [Google Académico](#).

Palabras Clave: Recomendador (Recommend), Sistema de Información (Information System), Sistema de Soporte a Decisiones (Decision Support Systems), Sistema Experto (Expert System), Algoritmo (Algorithm), Técnica de Inteligencia Artificial (Artificial Intelligence Technique), Suelo (Soil), Cultivo (Crop), Maiz (Corn, Maize), Rendimiento (Yield), y Productividad (Productivity). Se hicieron pruebas con las palabras clave anteriormente mencionadas. Las cadenas de

búsquedas utilizadas en las diferentes bases de datos se muestran en la Tabla 2. Las cadenas son muy similares por lo que solo se utilizaron los datos obtenidos por la cadena 1.

Tabla 2 Cadenas de búsqueda utilizadas.

Cadenas de búsqueda	
1	(Recommend OR Decision Support Systems OR Expert System OR Algorithm) AND (Crop OR Maize OR Corn) AND (Yield AND (Soil))
2	(Recommend OR Decision Support Systems OR Expert System OR Algorithm) AND (Crop OR Maize OR Corn) AND (Productivity) AND (Soil)

3) Seleccionar estudios

Para seleccionar los artículos utilizados, primeramente se leyeron los títulos y resúmenes de los estudios obtenidos por la cadena de búsqueda utilizada (Resultados), seleccionando aquellos sistemas que mejoren la productividad de los cultivos, mediante la recomendación o predicción del rendimiento, tomando en cuenta principalmente las propiedades del suelo (Primera Revisión). Después se aplicaron los criterios de exclusión sobre los estudios seleccionados en la primera revisión, obteniendo al final un total de 26 artículos de revistas que ayudaron a encontrar respuesta a las preguntas de investigación (Segunda Revisión). La tabla 3 nos

muestra la cantidad de artículos obtenidos en cada etapa de la selección.

Tabla 3 Número de artículos seleccionados por etapas.

Bases de Datos	Resultados	Primera Revisión	Segunda Revisión
<i>SciElo</i>	6	0	0
<i>IEEEExplore</i>	130	21	17
<i>ACM</i>	195	5	3
<i>Springer</i>	241	5	2
<i>ScienceDirect</i>	813	6	2
<i>Google Académico</i>	1200	10	2
TOTAL			26

Los criterios de exclusión tomados en cuenta se mencionan a continuación: a) La publicación usa herramientas de la agricultura de precisión, distintas a recomendadores o sistemas de soporte a decisiones, como los GIS, GPS, UAV, etc. b) El sistema recomendador ayuda en un área o etapa diferente a la selección de cultivos. c) La publicación está en un idioma diferente a inglés. d) La publicación es una revisión de literatura. e) La publicación fue publicada antes del 2017. f) La publicación no contesta las preguntas de investigación.

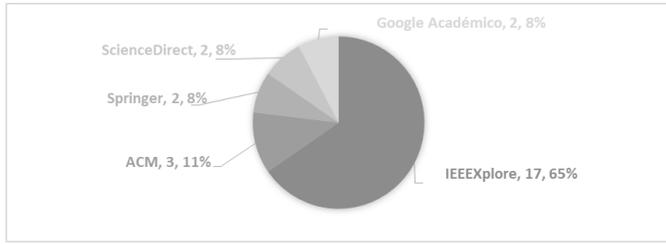


Figura 1 Cantidad de artículos seleccionados por base de datos.

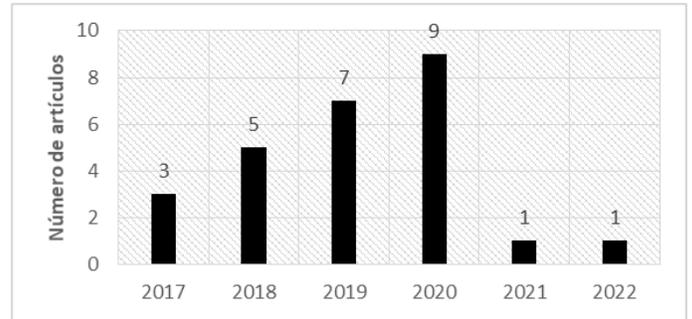


Figura 2 Cantidad de artículos seleccionados por año de publicación.

La figura 1 muestra la cantidad de artículos seleccionados de las diferentes bases de datos y el porcentaje correspondiente a cada una de ellas.

Se puede observar que la gran mayoría de los artículos fueron seleccionados de la base de datos IEEEXplore, 17 artículos de un total de 26, correspondiente al 65%.

La figura 2 muestra la cantidad de artículos seleccionados, ordenados por año de publicación, teniendo la mayor cantidad de artículos seleccionados correspondientes al año 2020, un total de 9, seguido del año 2019 con 7 artículos seleccionados.

4) Clasificar artículos y extraer

Para realizar la extracción de los artículos se generó un cuestionario con las cuatro preguntas principales y sus correspondientes subpreguntas, como se muestra en la Tabla 4.

Tabla 4 Cuestionario utilizado para la extracción de la información.

A Machine Learning Approach to Predict Crop Yield and Success Rate	
¿Cómo se integra el sistema recomendador?	
¿Para qué cultivo(s) se aplica el sistema?	20 cultivos, Girasol, Bajara, Jowar, Temporada, cacahuete, arroz, semilla de algodón, tur, etc.
¿Cuál es la finalidad del sistema?	El modelo sugiere el mejor cultivo posible con la mayor tasa de éxito. (Predicción)
¿De dónde se adquiere la información?	Los datos utilizados para la investigación se obtienen del sitio web del gobierno indio.
¿Existe un procesamiento de los datos utilizados?	Usando métodos estadísticos se analiza la relación entre diferentes variables.
¿A quién va dirigido?	A los agricultores
¿Qué métodos y técnicas utiliza el sistema de recomendación?	
¿Qué método o técnica se utiliza para generar la recomendación?	Redes Neuronales Artificiales
¿Qué variables utiliza para hacer la recomendación?	Área, Cultivo, Producción, Estado, Distrito, Temporada, Año y Producción
¿Con qué técnica se determinó la relación los datos?	Correlación Lienal o de Pearson
¿Qué herramientas fueron utilizadas para su desarrollo?	Python matplotlib, Seaborn, Pandas y TensorFlow
¿Cómo se presenta la salida del sistema?	visualización de un conjunto de datos con matplotlib y Biblioteca de python Seaborn
¿Cómo se valida el sistema?	
¿Cuál es el tamaño de la muestra utilizada?	12000 registros
¿Cuál fue la prueba o diseño experimental que realizaron?	Una red neuronal artificial de tres capas, con regresión lineal con propagación hacia adelante y hacia atrás Se utiliza una función de activación: unidad de
¿Cuál fue la métrica utilizada para su validación?	A. Error absoluto medio (MAE) B. Error cuadrático medio C. Error cuadrático medio de la raíz
¿Dónde fue evaluado?	Maharashtra, India
¿Cuáles fueron sus resultados?	El modelo predijo la variable dependiente con un 82% de precisión y muy poca pérdida.
¿Identifica algún otro tema abierto?	
¿Qué aporta a mi trabajo?	
¿Qué hicieron los autores?	El modelo ANN desarrolla una fórmula para determinar la relación utilizando una gran cantidad de ejemplos de entrada y salida, para establecer el modelo para las predicciones de
¿Qué aspecto puede resolver en mi trabajo?	Consideración de posibles entradas del sistema
¿Cómo podría serme de utilidad?	El uso de Redes Neuronales Artificiales

5) Realizar la agregación de datos.

El último paso consiste en sintetizar la información obtenida durante la extracción de cada uno de los artículos. Para esto se utilizó una matriz de agregación, como la que se muestra en la Figura 3.

Figura 3 Matriz de agregación de los datos.

RESULTADOS

En base a la matriz de agregación se pudo obtener respuesta a las cuatro preguntas de interés que se definieron al inicio de la metodología (Tabla 1).

1. ¿Cómo se integra el Sistema Recomendador?

Dentro de los sistemas de recomendación revisados el cultivo más utilizado para generar las recomendaciones fue el arroz (14.49%), seguido por el maíz y la caña de azúcar con un 7.25% y un 5.8% respectivamente. La Figura 4 muestra los cultivos con los que trabajaron los sistemas revisados. Como resultado de la revisión se encontró que las tres

principales finalidades de los sistemas recomendadores son: recomendar o sugerir el cultivo más adecuado en base a los parámetros considerados (38.46%), predecir el rendimiento de los cultivos (26.92%), y aumentar la productividad con un 19.23%. La Figura 5 muestra la finalidad de los diferentes sistemas revisados. La principal fuente de información declarada de estos sistemas proviene de páginas en línea (17.24%) y de información proporcionada por sensores aplicados directamente en los campos de cultivo (13.79%). En la Figura 6 se observan las diferentes fuentes de información con la que se alimentan los sistemas de recomendación. La gran mayoría de los sistemas se dirigen directamente a los agricultores (60.71%), para ayudarlos en la toma de decisión del cultivo y así aumentar su producción, rendimiento y ganancias (Fig. 7).

2. ¿Qué métodos o técnicas utiliza el Sistema de Recomendación?

La tabla 5 muestra que las principales técnicas en la selección de cultivos, son algoritmos de Machine Learning (ML), el más utilizado corresponde a Redes

Neuronales, con un 19.51% de los casos, seguido por los Sistemas de Lógica Difusa y Sistemas IoT con 12.2% y 9.76% respectivamente. La figura 8 muestra el número de veces que se utilizó cada una de las técnicas o métodos en los sistemas revisados. En cuanto a las variables de entrada que utilizan los diferentes sistemas, se encuentran en primer lugar el pH y el Nitrógeno con un 6.875%, seguido del Potasio con un 6.25%, en tercer lugar se encuentran el Fósforo y la Temperatura con un 5.625%. En la tabla 6 se pueden encontrar todos y cada uno de los parámetros considerados por los diferentes sistemas. Dentro de los artículos revisados, en la gran mayoría, no se mencionan las herramientas utilizadas para el desarrollo de los sistemas (44.44%), ni como se presentan los resultados de los mismos a los usuarios (55.56%). Dentro de los que si mencionan las herramientas de desarrollo, utilizaron principalmente Matlab, Python y WEKA, la primera con un 14.81% y las otras dos con un 11.11% cada una (Fig. 9), mientras que los resultados del sistema se presentan principalmente a través de una aplicación móvil (18.52%) o una página web (11.11%). La Figura 10

muestra las diferentes maneras de presentar los datos a los usuarios.

3. ¿Cómo se valida el Sistema?

Un 61.54% de los sistemas revisados no mencionan el tamaño de la muestra que utilizaron. Dentro de los que si lo hacen, se observa que el número de registros va de los 740 a los 12000.

La prueba más utilizada para medir la eficiencia de los algoritmos fue el estudio comparativo entre diferentes algoritmos de Machine learning a fin de utilizar el que mayor precisión obtenga (46.15%). Seguido por los experimentos realizados en campos agrícolas (19.23%). La Figura 11 muestra todas las pruebas y experimentos utilizados en los diferentes sistemas revisados.

La Figura 12 muestra las métricas utilizadas para validar los diferentes sistemas, se puede observar que la más utilizada para validar los sistemas es la Precisión (18.97%), seguida del Error Cuadrático Medio de la Raíz (RMSE) y la Validación Cruzada con un 10.34% cada uno.

La inmensa mayoría de estos sistemas fueron o están siendo desarrollados en la India, un 69.23%. La

figura 13 muestra los países donde fueron desarrollados los sistemas de recomendación de cultivos. Los sistemas de recomendación revisados arrojan una precisión que va del 82% al 99.91% entre los diferentes algoritmos o métodos utilizados.

4. ¿Qué aporta a mi trabajo?

Los autores hacen uso de diferentes técnicas de inteligencia artificial para ayudar a los agricultores a tomar una decisión sobre la elección del cultivo, en base a diferentes parámetros. Principalmente se hace una comparación entre varios algoritmos de aprendizaje automático, utilizando el mismo conjunto de datos, para así obtener la precisión de cada uno de ellos y elegir el que menor error demuestre con respecto a las métricas seleccionadas para su validación. Las herramientas de desarrollo, las pruebas y experimentos que se utilizaron en estos estudios revisados podrían ser de utilidad para lograr el objetivo de diseñar un algoritmo recomendador de maíces nativos en la región montañosa central del estado de Veracruz.

DISCUSIÓN

La revisión de la literatura demuestra que los sistemas de recomendación de cultivos cuentan con una estructura básica definida, la cual consiste en la *recopilación de datos*, los cuales se pueden obtener de páginas de internet de confianza, como pueden ser organizaciones y/o instituciones de gobierno encargadas de llevar el registro de estos datos, o mediante el uso de sensores que monitorean los parámetros necesarios para el funcionamiento del sistema, una vez que se cuenta con esta colección de datos se hace un *pre-procesamiento* de los mismos, para depurar los datos faltantes o atípicos que podrían generar problemas, después se hace una *extracción de características* mediante la identificación de los atributos más importantes y su relación, para posteriormente utilizar el *modelo de entrenamiento*, el cual puede ser más de uno, y así generar una comparación entre los modelos en base al *modelo de evaluación* y elegir el que mejor rendimiento otorgue (menor error), con lo cual se hace la *clasificación* de los cultivos y finalmente la *recomendación* sugerida como salida del sistema. El

principal problema observado entre los resultados obtenidos en la revisión y el sistema propuesto del recomendador de maíces nativos, es el acceso a la información necesaria para lograr generar la clasificación de las variedades de este grano, por lo que es necesario contar con un experto en este cultivo para poder comprender las relaciones entre los parámetros identificados y no identificados dentro de los sistemas de recomendación de cultivos revisados en esta investigación.

CONCLUSIONES

El desarrollo de sistemas recomendadores de cultivos está definido de manera general, lo más importante de estos sistemas es la información con la cual se alimentan, la recomendación depende del tipo y la cantidad de datos alimentados, por lo que si no se cuenta con la información necesaria, la recomendación podría no ser la esperada. Por lo que el principal problema respecto al algoritmo

recomendador propuesto recae en la poca o casi nula información registrada en estudios relacionados con parámetros del suelo importantes necesarios para generar las recomendaciones, puesto que el maíz nativo y las razas que se reconocen no cuentan con una información completa a nivel de componentes del suelo y propiedades necesarias para su desarrollo, es por ello necesario contar con la ayuda de expertos en el área y en base a su conocimiento generar un sistema experto basado en reglas. Puesto que el sistema propuesto tiene la finalidad de recomendar la semilla de maíz nativo que más convenga al agricultor en base a parámetros ambientales como del suelo, se deben de agregar los diferentes usos específicos que tienen cada una de las razas, esto espera lograr que, al hacer uso de las semillas nativas se promueva la conservación de las mismas y así mantener la soberanía alimentaria de la región montañosa central del estado de Veracruz.

BIBLIOGRAFÍA

- Arooj, A., Riaz, M., & Akram, M. N. (2018). Evaluation of predictive data mining algorithms in soil data classification for optimized crop recommendation. *2018 International Conference on Advancements in Computational Sciences (ICACS)*, 1–6. <https://doi.org/10.1109/icacs.2018.8333275>
- Barbosa, A., Trevisan, R., Hovakimyan, N., & Martin, N. F. (2020). Modeling yield response to crop management using convolutional neural networks. *Computers and Electronics in Agriculture*, *170*, 105197. <https://doi.org/10.1016/j.compag.2019.105197>
- Bhanumathi, S., Vineeth, M., & Rohit, N. (2019). Crop Yield Prediction and Efficient use of Fertilizers. *2019 International Conference on Communication and Signal Processing (ICCSP)*, 769–773. <https://doi.org/10.1109/iccsp.2019.8698087>
- Castro, P. J. M., Caliwag, J. A., Pagaduan, R. A., Arpia, J. M., & Delmita, G. I. (2019). A Mobile Application for Organic Farming Assistance Techniques using Time-Series Algorithm. *Proceedings of the 2019 2nd International Conference on Information Science and Systems*, 120–124. <https://doi.org/10.1145/3322645.3322697>
- Deepa, N., & Ganesan, K. (2018). Hybrid rough fuzzy soft classifier based multi-class classification model for agriculture crop selection. *Soft Computing*, *23*(21), 10793–10809. <https://doi.org/10.1007/s00500-018-3633-8>
- Kale, S. S., & Patil, P. S. (2019). A Machine Learning Approach to Predict Crop Yield and Success Rate. *2019 IEEE Pune Section International Conference (PuneCon)*, 1–5. <https://doi.org/10.1109/punecon46936.2019.9105741>
- Katarya, R., Raturi, A., Mehndiratta, A., & Thapper, A. (2020). Impact of Machine Learning

- Techniques in Precision Agriculture. 2020 3rd International Conference on Emerging Technologies in Computer Engineering: Machine Learning and Internet of Things (ICETCE), 1–6. <https://doi.org/10.1109/icetce48199.2020.9091741>
- Kitchenham, B. (2004). Procedures for Performing Systematic Reviews. Keele: Keele University Technical Report TR/SE-0401.
- Kuanr, M., Rath, B., & Mohanty, S. (2018). Crop Recommender System for the Farmers using Mamdani Fuzzy Inference Model. *International Journal of Engineering & Technology*, 277–280. https://drsachinandan.com/publication/17%20ACFrOgCg2usVBT5ead-RpoQJQH-sAQX7LHUGqa7iMosdjK8w57PjzbzCPAgnBJ2HhqWySWxiGUzeIavy9NHwieXuDCK2NjsmFAoOLbFd1fre9jef_DWF3Dv6_Y9obDbh8RWasHvHBjvhz2mpTRIKr.pdf
- Kulkarni, N. H., Srinivasan, G. N., Sagar, B. M., & Cauvery, N. K. (2018). Improving Crop Productivity Through A Crop Recommendation System Using Ensembling Technique. 2018 3rd International Conference on Computational Systems and Information Technology for Sustainable Solutions (CSITSS), 114–119. <https://doi.org/10.1109/csitss.2018.8768790>
- Meeradevi, Sanjana, V., & Mundada, M. R. (2019). Decision Support System to Agronomically Optimize Crop Yield based on Nitrogen and Phosphorus. 2019 4th International Conference on Computational Systems and Information Technology for Sustainable Solution (CSITSS), 1–6. <https://doi.org/10.1109/csitss47250.2019.9031054>
- Mishra, S., Paygude, P., Chaudhary, S., & Idate, S. (2018). Use of data mining in crop yield prediction. 2018 2nd International Conference on Inventive Systems and Control (ICISC), 796–802. <https://doi.org/10.1109/icisc.2018.8398908>

- Ngo, V., & Kechadi, M. (2020). Crop Knowledge Discovery Based on Agricultural Big Data Integration. *Proceedings of the 4th International Conference on Machine Learning and Soft Computing*. <https://doi.org/10.1145/3380688>
- Pande, S. M., Ramesh, P. K., Anmol, A., Aishwarya, B. R., Rohilla, K., & Shaurya, K. (2021). Crop Recommender System Using Machine Learning Approach. *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, 1066–1071. <https://doi.org/10.1109/iccmc51019.2021.9418351>
- Prabakaran, G., Vaithiyathan, D., & Ganesan, M. (2018). Fuzzy decision support system for improving the crop productivity and efficient use of fertilizers. *Computers and Electronics in Agriculture*, 150, 88–97. <https://doi.org/10.1016/j.compag.2018.03.030>
- Pudumalar, S., Ramanujam, E., Rajashree, R. H., Kavya, C., Kiruthika, T., & Nisha, J. (2017). Crop recommendation system for precision agriculture. *2016 Eighth International Conference on Advanced Computing (ICoAC)*, 32–36. <https://doi.org/10.1109/icoac.2017.7951740>
- Rajeswari, A., Anushiya, A., Fathima, K. A., Priya, S., & Mathumithaa, N. (2020). Fuzzy Decision Support System for Recommendation of Crop Cultivation based on Soil Type. *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI) (48184)*, 768–773. <https://doi.org/10.1109/icoei48184.2020.9142899>
- Reshma, R., Sathiyavathi, V., Sindhu, T., Selvakumar, K., & SaiRamesh, L. (2020). IoT based Classification Techniques for Soil Content Analysis and Crop Yield Prediction. *2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 156–160. <https://doi.org/10.1109/i-smac49090.2020.9243600>

- Rizaldi, T., Putranto, H. A., Riskiawan, H. Y., Setyohadi, D. P. S., & Riaviandy, J. (2019). Decision Support System for Land Selection to Increase Crops Productivity in Jember Regency Use Learning Vector Quantization (LVQ). *2019 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE)*, 82–85. <https://doi.org/10.1109/icomitee.2019.8921033>
- Sakthi, U., & Rose, J. D. (2020). Smart Agricultural Knowledge Discovery System using IoT Technology and Fog Computing. *2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)*, 48–53. <https://doi.org/10.1109/icssit48917.2020.9214102>
- Shirsath, R., Khadke, N., More, D., Patil, P., & Patil, H. (2017). Agriculture decision support system using data mining. *2017 International Conference on Intelligent Computing and Control (I2C2)*, 1–5. <https://doi.org/10.1109/i2c2.2017.8321888>
- Shu, K. (2020). Prediction of Soybean Yield using Self-normalizing Neural Networks. *Proceedings of the 2020 5th International Conference on Machine Learning Technologies*, 51–55. <https://doi.org/10.1145/3409073.3409092>
- Shylaja, S. N., & Veena, M. B. (2017). Real-time monitoring of soil nutrient analysis using WSN. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)*, 3059–3062. <https://doi.org/10.1109/icecde.2017.8390018>
- Tobing, D. M. L., Kurniasih, J., Tetik, Y. N., & Kusriani. (2019). The Prototype of Decision Support System For Selecting The Lands of Crops. *2019 4th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, 276–280. <https://doi.org/10.1109/icitisee48480.2019.9003836>

Uddin, M., & Hassan, M. R. (2022). A novel feature based algorithm for soil type classification. *Complex & Intelligent Systems*, 1–17. <https://doi.org/10.1007/s40747-022-00682-0>

Varsha, A., Midhuna, V., & Rilty, R. (2020). Agrotech: Soil Classification and Crop Recommendation. *Journal of Research in Engineering, Science and Management*, 202–205.

https://www.ijresm.com/Vol.3_2020/Vol3_Iss6_June20/IJRESM_V3_I6_54.pdf

Vigneswaran, E. E., & Selvaganesh, M. (2020). Decision Support System for Crop Rotation Using Machine Learning. *2020 Fourth International Conference on Inventive Systems and Control (ICISC)*, 925–930. <https://doi.org/10.1109/icisc47916.2020.9171120>

ANEXOS

Tabla 5 Diferentes técnicas y métodos utilizados por los sistemas revisados.

Métodos	Técnicas	Autor(es)	No.
Redes Neuronales	<ul style="list-style-type: none"> • <i>Redes Neuronales Artificiales (ANN)</i> • <i>Backpropagation</i> • <i>Red Neuronal Recurrente (RNN)</i> • <i>Learning Vector Quantization (LVQ)</i> • <i>Red Neuronal Convolutacional (CNN)</i> • <i>Redes Neuronales Autonormalizantes (SNN)</i> 	(Shirsath et al., 2017) (Kale & Patil, 2019) (Bhanumathi et al., 2019) (Meeradevi et al., 2019) (Rizaldi et al., 2019) (Barbosa et al., 2020) (Shu, 2020) (Pande et al., 2021)	8
Machine Learning	<ul style="list-style-type: none"> • <i>Decision Tree J48</i> • <i>BF Tree</i> • <i>OneR</i> • <i>Naïve Bayes</i> • <i>Máquina de vectores de soporte (SVM)</i> • <i>Regresión lineal multivariante (MLR)</i> • <i>Vecino más cercano (KNN)</i> • <i>Random Forest (RF)</i> • <i>Logistic Regression</i> • <i>Decision Table</i> 	(Arooj et al., 2018) (Mishra et al., 2018) (Katarya et al., 2020)	3
Ensamblaje		(Pudumalar et al., 2017) (Kulkarni et al., 2018)	2
Lógica Difusa	<ul style="list-style-type: none"> • <i>Lógica Difusa</i> • <i>Neuro-Fuzzy</i> • <i>Mamdani Fuzzy Inference</i> • <i>Z-soft fuzzy</i> 	(Kuanr et al., 2018) (Prabakaran et al., 2018) (Deepa & Ganesan, 2019) (Rajeswari et al., 2020) (Vigneswaran & Selvaganesh, 2020)	5
IoT		(Shylaja & Veena, 2017) (Reshma et al., 2020) (Sakthi & Rose, 2020) (Varsha et al., 2020)	4
Método Topsis y Sistemas Expertos		(Tobing et al., 2019)	1
Promedio móvil de series de tiempo		(Castro et al., 2019)	1
Big Data		(Ngo & Kechadi, 2020)	1
Visión artificial		(Uddin & Hassan, 2022)	1
TOTAL			26

Tabla 6 Parámetros y el número de veces utilizados por los diferentes sistemas de recomendación de cultivos.

#	Parámetro	No. de Veces	%	#	Parámetro	No. de Veces	%
1	pH	11	6.88 %	21	Retención de agua	3	1.88 %
2	Nitrógeno (N)	11	6.88 %	22	Manganeso (Mn)	3	1.88 %
3	Potasio (K)	10	6.25 %	23	Materia orgánica (MO) del suelo	3	1.88 %
4	Fósforo (P)	9	5.63 %	24	Estado	2	1.25 %
5	Temperatura (°C)	9	5.63 %	25	Color del suelo	2	1.25 %
6	Cultivo	8	5.00 %	26	Urea	2	1.25 %
7	Temporada	7	4.38 %	27	Calcio (Ca)	2	1.25 %
8	Área	6	3.75 %	28	Azufre (S)	2	1.25 %
9	Distrito	6	3.75 %	29	Boro (B)	2	1.25 %
10	Precipitación (mm)	6	3.75 %	30	Altitud	2	1.25 %
11	Conductividad eléctrica del suelo (EC)	6	3.75 %	31	herbicidas e insecticidas	2	1.25 %
12	Tipo de suelo	6	3.75 %	32	Profundidad	1	0.63 %
13	Año	4	2.50 %	33	Permeabilidad	1	0.63 %
14	Textura	4	2.50 %	34	Drenaje	1	0.63 %
15	Magnesio (Mg)	4	2.50 %	35	Erosión	1	0.63 %
16	Hierro (Fe)	4	2.50 %	36	Molibdeno (Mo)	1	0.63 %
17	Zinc (Zn)	4	2.50 %	37	Metano	1	0.63 %
18	Cobre (Cu)	4	2.50 %	38	Imagen satelital	1	0.63 %
19	Humedad (HR)	4	2.50 %	39	Precio	1	0.63 %
20	Producción	3	1.88 %	40	No menciona	1	0.63 %
TOTAL						160	100 %

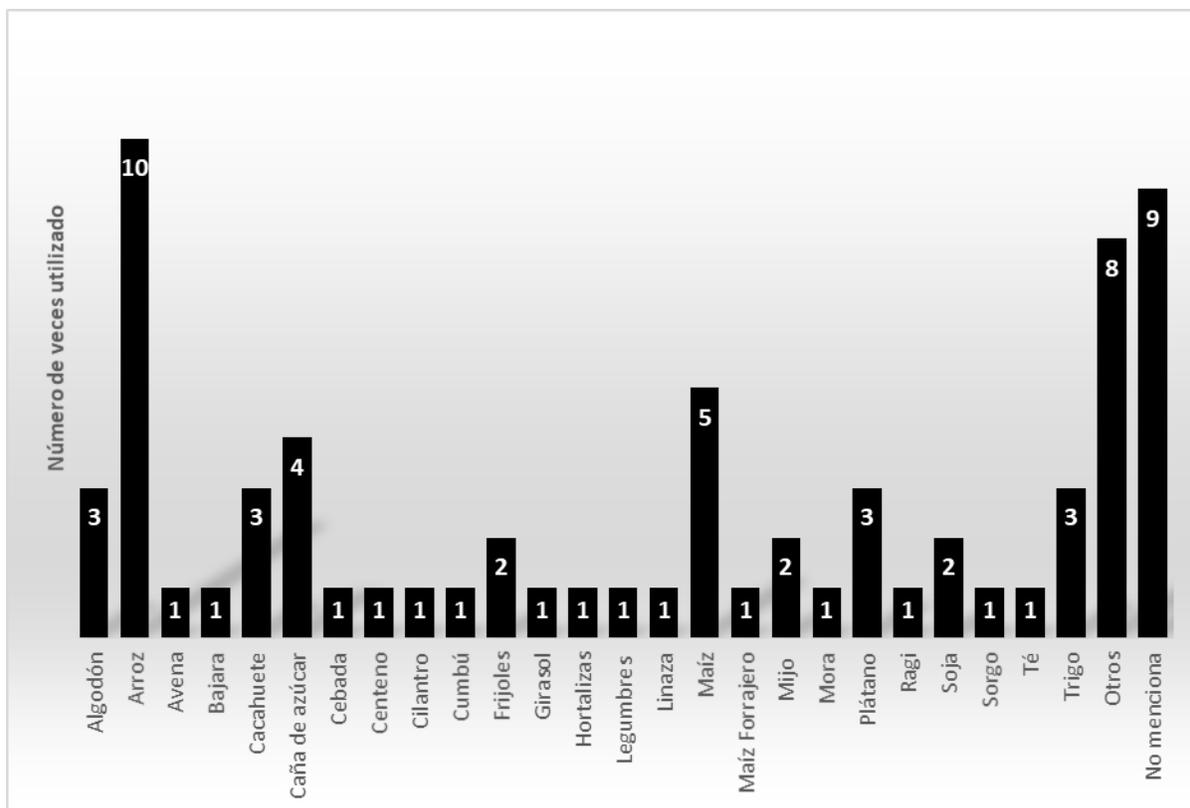


Figura 4 Cultivos trabajados por los diferentes sistemas.

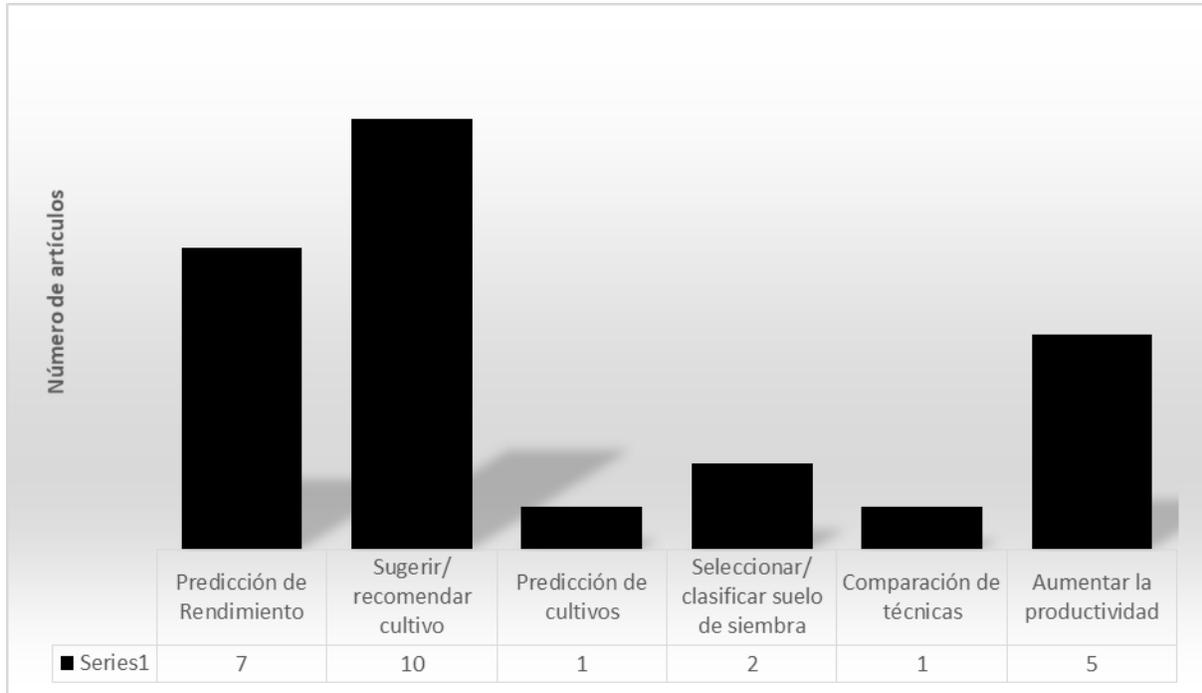


Figura 5 Finalidad de los diferentes sistemas recomendadores.

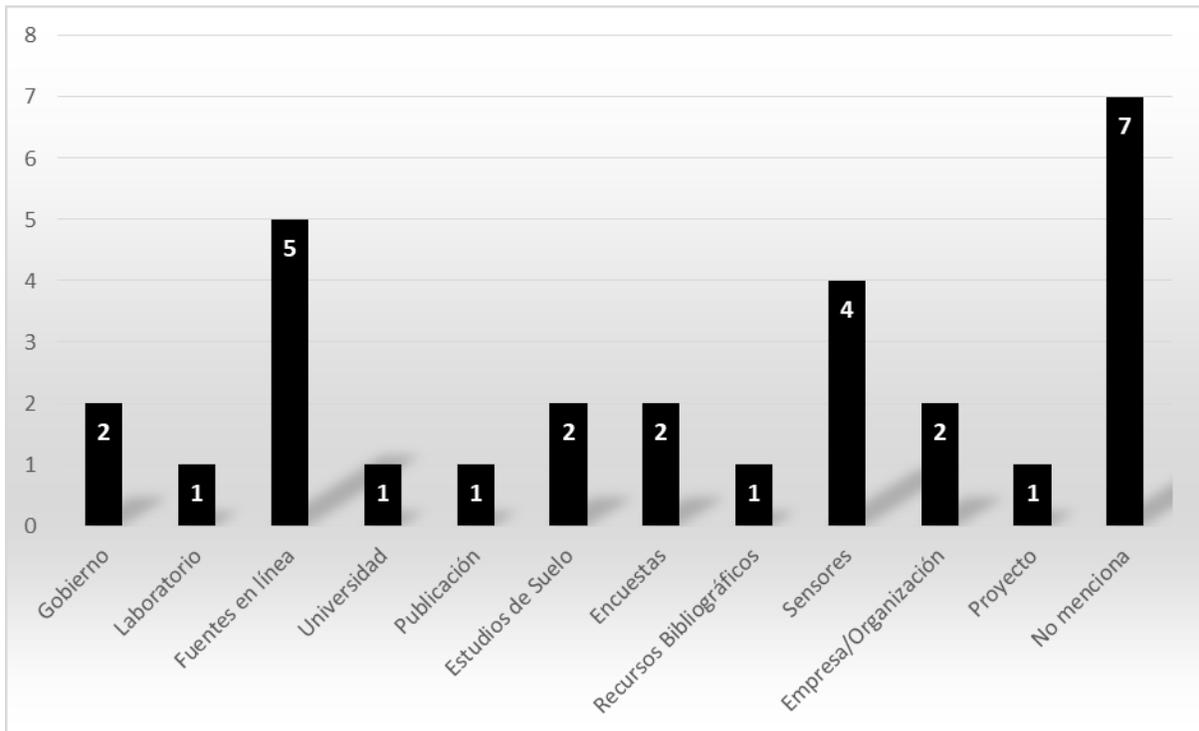


Figura 6 Fuentes de información que alimenta a los diferentes sistemas.

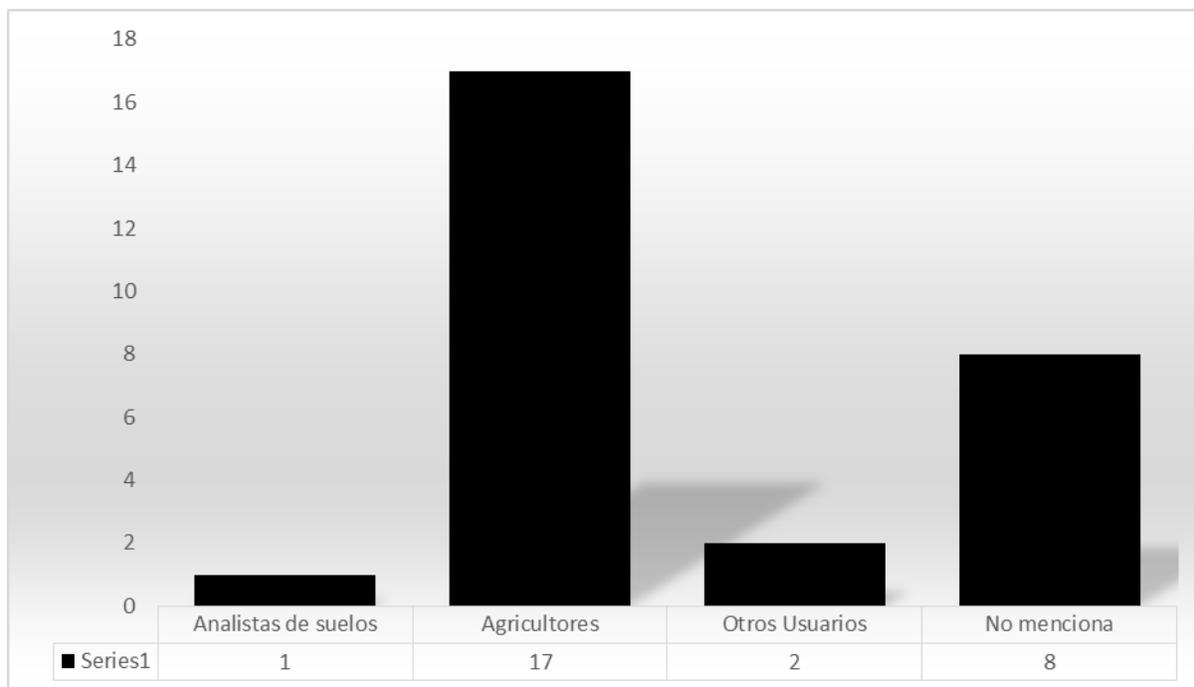


Figura 7 Diferentes usuarios para los que van dirigidos los sistemas de recomendación.

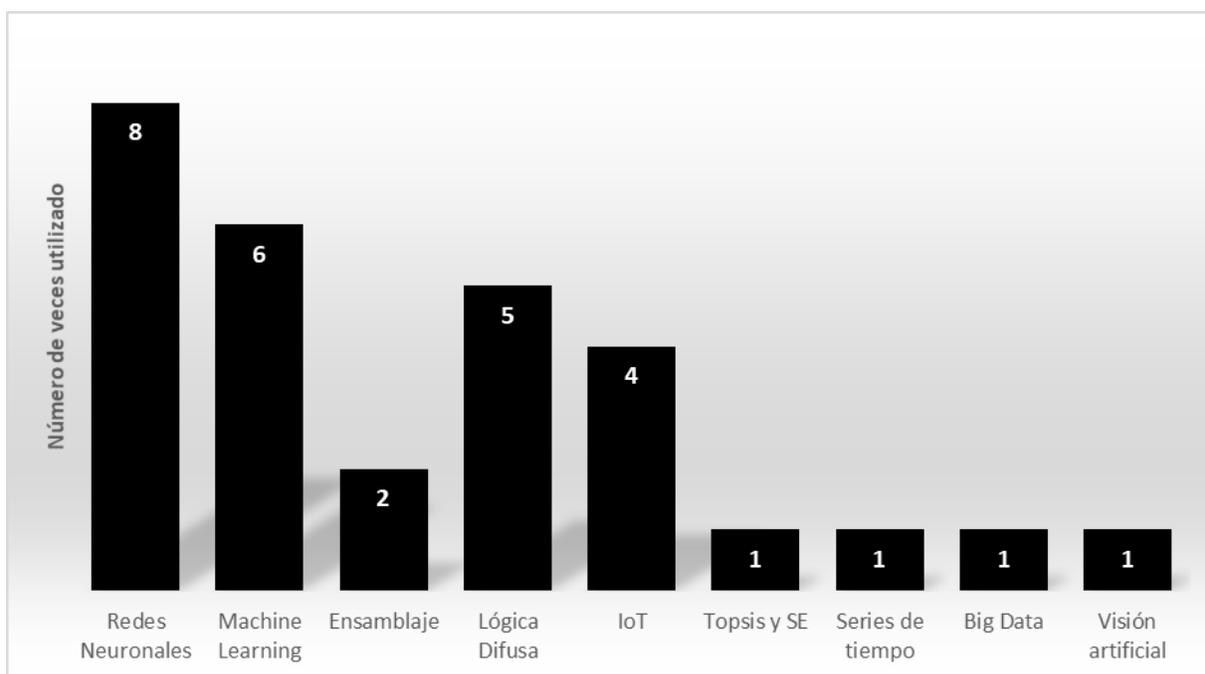


Figura 8 Diferentes métodos y técnicas utilizadas por los sistemas de recomendación de cultivos.

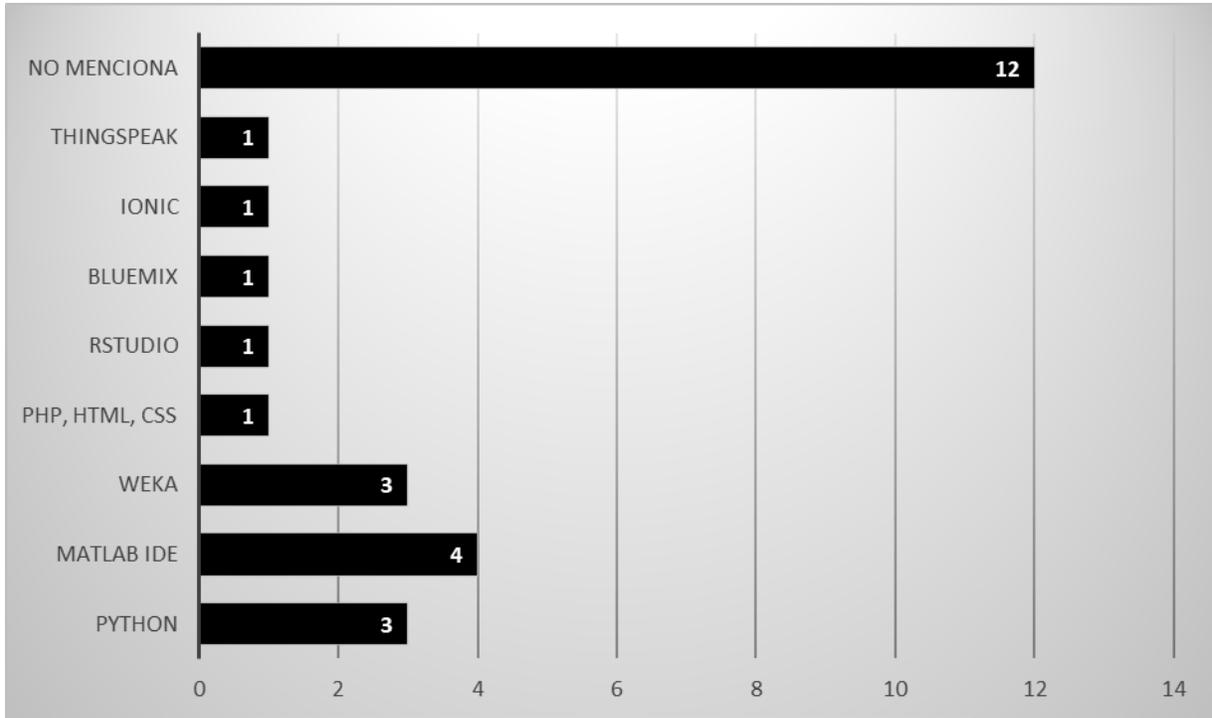


Figura 9 Herramientas tecnológicas de desarrollo utilizadas por los sistemas revisados.

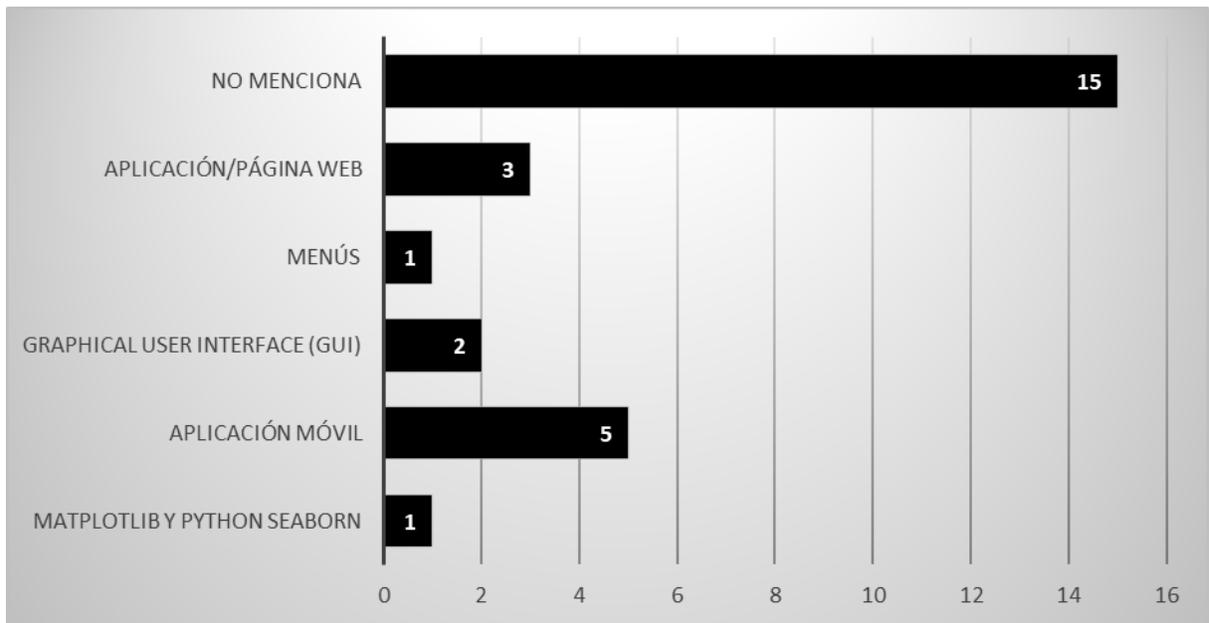


Figura 10 Diferentes salidas de los sistemas presentados al usuario final.

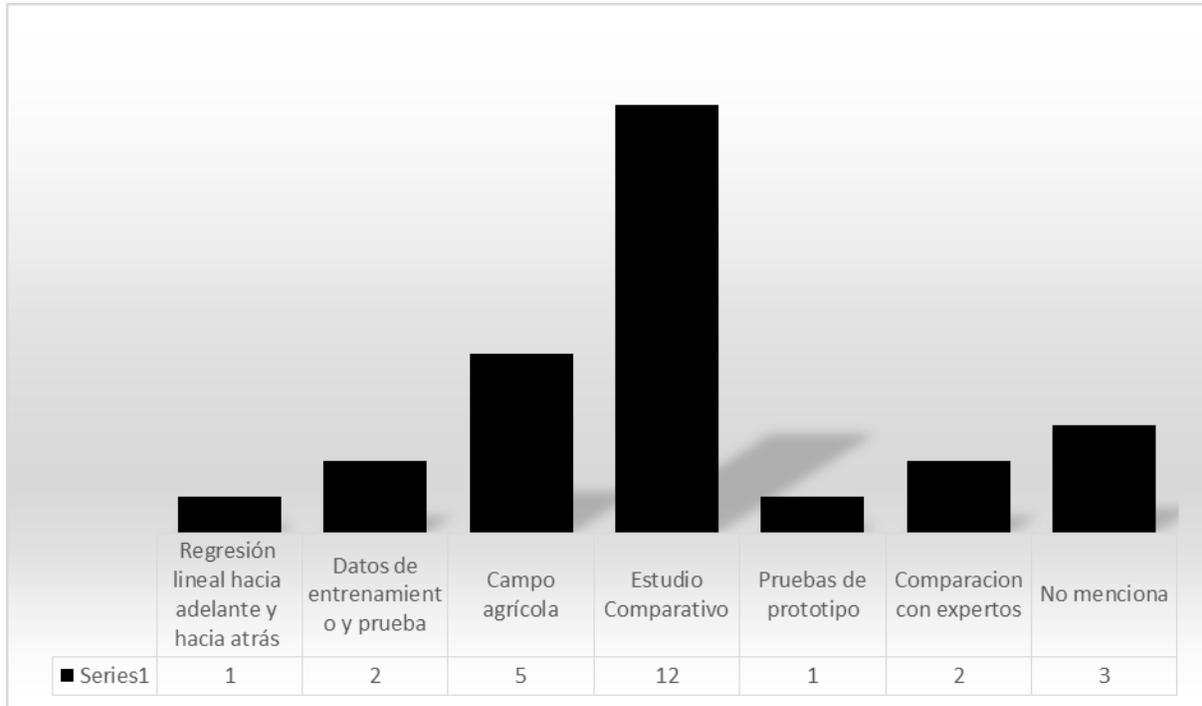


Figura 11 Pruebas y experimentos realizados sobre los sistemas revisados.



Figura 12 Métricas utilizadas para la validación de los sistemas revisados.

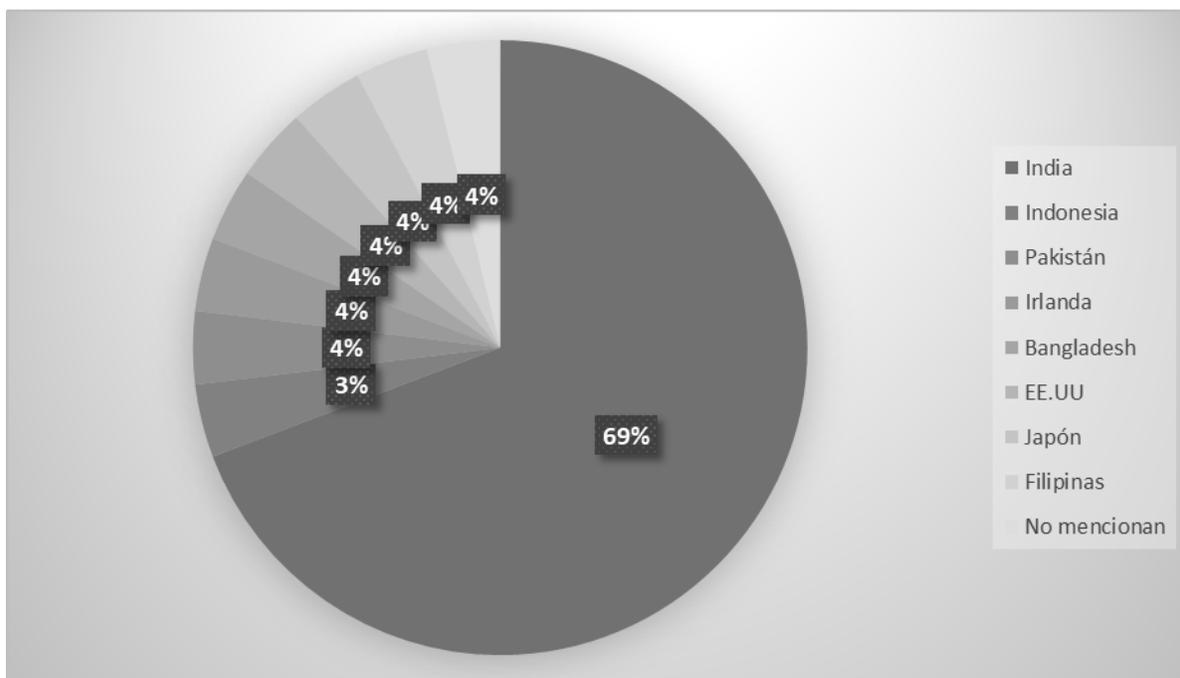


Figura 13 Países en donde se realizó el desarrollo de los sistemas de recomendación revisados.