
Modelos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*: Una Revisión Sistemática de la Literatura

Machine learning models for disease classification of *Solanum tuberosum*: A Systematic Review of the Literature

Joel Saul Moreno Mayhuire

<https://orcid.org/0009-0008-0998-4890>
joel.moreno1@unmsm.edu.pe

José Alfredo Herrera Quispe

<https://orcid.org/0000-0002-8207-9714>
jherreraqu@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos, Lima, Perú

RECIBIDO: 30/10/2023 - ACEPTADO: 25/11/2023 - PUBLICADO: 30/12/2023

RESUMEN

Las enfermedades de la *Solanum tuberosum* consideradas como uno de los factores muy importantes en su producción, influyen en la calidad de los productos finales y también en el mercado de estos productos. Actualmente los procesos de clasificación están tomando bastante interés en la agricultura a nivel global, al igual que los análisis de los diferentes defectos que presenta la *Solanum tuberosum*. Por ello los investigadores están desarrollando nuevos algoritmos para la detección de enfermedades utilizando tecnologías de inteligencia artificial, con el fin de optimizar la detección de enfermedades o defectos. En este trabajo se presenta un análisis de las investigaciones acerca de la construcción de modelos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*, además revisar qué enfermedades son los más comunes e impactantes de este producto y determinar cuál de los modelos entrenados son los más eficientes en la clasificación de enfermedades de este producto y ayudar a los investigadores en el futuro construir sistemas de detección y clasificación automática de las enfermedades y defectos de la *Solanum tuberosum*.

Palabras clave: *Solanum tuberosum*, aprendizaje automático, clasificación, inteligencia artificial.

ABSTRACT

Solanum tuberosum diseases, considered one of the very important factors in its production, influence the quality of the final products and also the market for these products. Currently, classification processes are taking a lot of interest in agriculture globally, as are the analyzes of the different defects that *Solanum tuberosum* presents. For this reason, researchers are developing new algorithms for disease detection using artificial intelligence technologies, in order to optimize the detection of diseases or defects. This work presents an analysis of research on the construction of machine learning models for the classification of diseases of *Solanum tuberosum*, also reviewing which diseases are the most common and impactful of this product and determining which of the trained models are the most efficient in the classification of diseases of this product and help researchers in the future build automatic detection and classification systems for diseases and defects of *Solanum tuberosum*.

Keywords: *Solanum tuberosum*, machine learning, classification, artificial intelligence.

I. INTRODUCCIÓN

La papa (*Solanum tuberosum*) constituye el cuarto alimento de mayor consumo en el mundo y su producción, a nivel mundial, es de unos 320 millones de toneladas por año. Su cultivo se encuentra presente en más de cien países. Entre ellos, los de América del Norte y Europa vienen siendo de los mayores productores, aunque en las últimas décadas hubo un crecimiento extraordinario de estas plantaciones en Asia, África y América Latina (Borba, 2008). Por su gran variedad se ha puesto bastante interés en la mejora de la producción para poder adaptarse a las exigencias de los consumidores en cuanto a la calidad del producto, por lo que la clasificación como uno de los procesos más importantes en su producción es bastante estudiada actualmente y además se están buscando los métodos para mejorar la eficiencia en la clasificación del producto.

En este artículo de revisión se realiza una búsqueda exhaustiva de las investigaciones acerca de la construcción de modelos de clasificación con algoritmos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*. Además determinar cuáles son las enfermedades más comunes y cuáles han sido estudiadas con estos algoritmos.

II. MÉTODOS Y MATERIALES

La presente revisión sistemática se la realizado con la metodología PRISMA (Preferred Reporting Items for Systematic Review and Meta-Analysis).

Tabla 1

Preguntas de investigación.

Nº	Pregunta de investigación
RQ1	¿Qué algoritmos se utilizan para la clasificación de enfermedades o defectos de la <i>Solanum tuberosum</i> ?
RQ2	¿Cómo se recopilaron los datos que se utilizaron en las investigaciones?
RQ3	¿Qué enfermedades o defectos de la <i>Solanum tuberosum</i> se analizan en las investigaciones?
RQ4	¿Cuál es el rendimiento de los modelos o métodos de clasificación que se realizaron en las investigaciones?

La búsqueda de las investigaciones se realizaron con las principales bases de datos de investigaciones: Scopus, Web Of Science y ScienceDirect, sobre la clasificación de enfermedades y defectos de la *Solanum tuberosum* usando algoritmos de aprendizaje automático con la cadena de

búsqueda y los criterios de inclusión y exclusión se pudo obtener las investigaciones que fueron analizadas minuciosamente.

2.1. Objetivos de la investigación

El objetivo de esta Revisión Sistemática es proporcionar un panorama general de las investigaciones en los últimos cinco años de los modelos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*, teniendo en conocimiento que la clasificación y detección de enfermedades de la *Solanum tuberosum* es uno de los procesos más importantes en el proceso de la agricultura y teniendo en cuenta además que la *Solanum tuberosum* es uno de los productos más consumidos a nivel mundial y por ello también necesitan que las nuevas tecnologías de inteligencia artificial ayuden en su proceso y optimizar su calidad al momento de seleccionarlos. También con este trabajo se va poder ayudar a los investigadores para que puedan realizar trabajos similares o desarrollar sistemas automáticos de clasificación con inteligencia artificial.

2.2. Estrategias de búsqueda

Se han utilizado tres bases de datos: Scopus, Web of Science y ScienceDirect y se aplicaron los filtros para seleccionar estudios desde el año 2019 hasta la actualidad, es decir que se consideraron investigaciones con una antigüedad no mayor a 5 años. La consulta de búsqueda utilizada tiene la siguiente combinación de palabras clave: "**CLASIFICACION MACHINE LEARNING SOLANUM TUBEROSUM**". El string de búsqueda exacto fue: TITLE-ABS-KEY(("Solanum tuberosum" OR "potato tuber") AND ("machine learning classification" OR "deep learning classification" OR "image processing" OR "machine learning detection" OR "machine learning identification" OR "machine learning ordination")) AND (model OR algorithm OR technic)) AND (LIMIT-TO(SUBJAREA,"COMP") OR LIMIT-TO(SUBJAREA,"ENGI") OR LIMIT-TO(SUBJAREA,"MATH")) AND (LIMIT-TO(PUBYEAR,2019) OR LIMIT-TO(PUBYEAR,2020) OR LIMIT-TO(PUBYEAR,2021) OR LIMIT-TO(PUBYEAR,2022) OR LIMIT-TO(PUBYEAR,2023))(ver Figura 1).

2.3. Los criterios de inclusión y exclusión

Se realizó una primera exclusión de artículos mediante un proceso, ordenando los títulos y la eliminación de los duplicados, de un total de 170 documentos, 6 eran duplicados.

Figura 1

Metodología PRISMA.

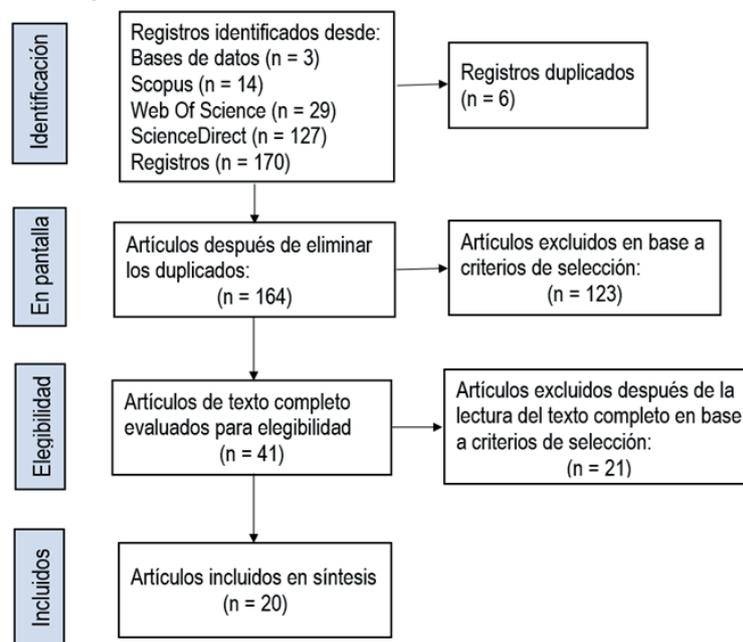


Tabla 2

Eliminación de duplicados.

Duplicados	6	3.53%
Seleccionados	164	97.47%
Total	170	100%

Luego se realizó una revisión por **Título y por Abstract**, en la que se excluyeron documentos mediante los criterios: C1: ¿El título del documento hace referencia al uso de algoritmos de machine learning para la detección de enfermedades o defectos de la Solanum tuberosum?. C2: ¿El Abstract trata de algoritmos de machine learning para la detección de enfermedades o defectos de la Solanum tuberosum?. Los documentos que llevaron a respuestas positivas en ambas cuestiones fueron seleccionados, el resto fueron descartados.

Tabla 3

Selección por Título y por Abstract

Si: Título y Abstract	41	25%
No Relac.	123	75%
Total / Criterio	164	100%

2.4. Selección de estudios

Luego se continuó la revisión sistemática y se aplicaron criterios de exclusión por contenido del artículo, se plantearon los criterios de exclusión:

CE1: ¿El artículo trata sobre el tema del uso de algoritmos de machine learning para la clasificación de enfermedades o defectos de la Solanum tuberosum?. CE2: ¿El artículo de investigación tiene como objetivo realizar el análisis de enfermedades o defectos de la Solanum tuberosum?. Es decir si el documento respondía afirmativamente a ambas preguntas fue seleccionado, los artículos elegidos por criterio de exclusión fueron 20 de 41.

Tabla 4

Selección por criterio de elegibilidad.

Elegidos	20	48.78%
No elegidos	21	51.22%
Total	41	100%

III. RESULTADOS Y DISCUSIÓN

Las preguntas de investigación planteadas son:

(RQ1) ¿Qué algoritmos se utilizan para la detección de enfermedades o defectos de la Solanum tuberosum?

(RQ2) ¿Cómo se recopilaron los datos que se utilizaron en las investigaciones?

(RQ3) ¿Qué enfermedades o defectos de la Solanum tuberosum se analizan en las investigaciones?

(RQ4) ¿Cuál es el rendimiento de los modelos o métodos de clasificación que se realizaron en las investigaciones?

Después de realizar la Revisión Sistemática de la Literatura, se pueden dar las respuestas.

3.1. Respuestas a RQ1

Los algoritmos que se utilizan en la clasificación de enfermedades o defectos de la *Solanum tuberosum* están resumidos en la tabla 5.

En respuesta a RQ1 como se visualiza en la Tabla 5, cada uno de los 20 artículos contiene diferentes algoritmos de clasificación de enfermedades o defectos de la *Solanum tuberosum*. Los cuales fueron entrenados y analizados. Se puede visualizar que las Redes Neuronales son los más utilizados en este tipo de clasificaciones, seguido de los algoritmos comunes de machine learning.

3.2. Respuesta a RQ2

En la tabla 6 se visualiza cómo se recopilaron los datos para realizar las investigaciones.

3.3. Respuesta a RQ3

Al revisar las investigaciones se puede apreciar una serie de enfermedades que están presentes en la *Solanum tuberosum*. También en otras investigaciones se analizan los defectos y calidades que es muy fundamental al momento de clasificarlos.

Las enfermedades y defectos que se analizan en las investigaciones están resumidas en la Tabla 7.

3.4. Respuestas a RQ4

El rendimiento de los modelos de clasificación de los 20 artículos de investigación se realizaron a través de métricas de rendimiento de los modelos de clasificación con sus puntuaciones de calidad obtenidos y se detallan en la Tabla 8.

3.5. Resultados bibliométricos

Se obtubieron las figuras 2-4.

IV. CONCLUSIÓN

En la presente investigación se realizó una Revisión Sistemática de la Literatura sobre el uso de

Tabla 5

Algoritmos y métodos de clasificación.

Autores	Algoritmo
(Van De Vijver et al., 2020)	PLS-DA, SVM, Decision tree
(Suarez at al., 2022)	CNN, SVM.
(Rashid et al., 2021)	CNN, YOLOv5
(Rodriguez et al., 2021)	Random Forest, Gradient Boosting Classifier, Support Vector Classifier, Linear Support Vector Classifier, K-Nearest Neighbors Classifier.
(Jang et al., 2023)	YOLOv5, DeepSORT.
(Zhao et al., 2022)	MC-YOLOv4, K-means ++.
(Salvador et al., 2020)	Random Forest, Support Vector Machine Linear, Support Vector Machine Polynomial, Support Vector Machine Radial, General Linear Model.
(Shin at al., 2023)	RNN, ANN pattern recognition.
(Garcia at al., 2023)	K-Means, Hierarchical clustering.
(Kang et al., 2023)	CNN
(Przybylak et al., 2020)	Red Neuronal de Perceptrón de tres capas
(Oppenheim et al., 2019)	CNN
(Przybyl et al., 2019)	MLP
(Hassoon et al., 2021)	FFNN, K-means
(Yu et al., 2022)	Distancia de Hausdorff, Intersección sobre unión (IoU).
(Hussain et al., 2021)	GoogLeNet, VGG-16, EfficientNet-B0
(Afonso et al., 2019)	ResNet18, ResNet50.
(Ibrahim at al., 2020)	Gray-Level Co-Occurrence Matrices (GLCM)
(Siebring et al., 2019)	Random Forest
(Qi et al., 2023)	2D-CNN, 3D-CNN, Random Forest, PLB-2D-3D-A.

Tabla 6

Método de recopilación de datos.

Autores	Recopilación de datos
(Van De Vijver et al., 2020)	Imágenes hiperspectrales de alta resolución en el campo.
(Suarez et al., 2022)	Imágenes directamente de los cultivos.
(Rashid et al., 2021)	Captura de imágenes de hojas de papa de la región central de Punjab en Pakistán, conjunto de datos de PlantVillage.
(Rodríguez et al., 2021)	Imágenes multiespectrales con UAV sobre el campo de papa.
(Jang et al., 2023)	Imágenes obtenidas mediante un prototipo de captura de imágenes de papa.
(Zhao et al., 2022)	Imágenes recopiladas en el sitio de prueba Baima en la Universidad Agrícola de Nanjing China, 2000 imágenes.
(Salvador et al., 2020)	Conjunto de datos ERA5 (ECMWF Re-Analysis) por el Servicio de Cambio Climático de Copernicus.
(Shin et al., 2023)	Imágenes de plantas de patata inoculadas con <i>Verticillium dahlia</i> .
(García et al., 2023)	Procesamiento de la imagen de patatas, Extracción de características, Selección de características.
(Kang et al., 2023)	Recolección y etiquetado de 5450 imágenes de papa.
(Przybylak et al., 2020)	Papas de la variedad Gala obtenidas en Dabrowa Biskupia Polonia, Procesamiento de imágenes.
(Oppenheim et al., 2019)	Se tomaron fotos de 400 tubérculos de papa.
(Przybyl et al., 2019)	Imágenes de cinco variedades de patatas: Denar, Lord, Gala, Nandina y Vineta de Polonia.
(Hassoon et al., 2021)	Recopilación de 120 imágenes de papa. Extracción de características.
(Yu et al., 2022)	La muestra de prueba consistió en 273 papas, incluidas 75 papas irregulares. Captura de imágenes con un prototipo. Preprocesamiento de imágenes.
(Hussain et al., 2021)	Las imágenes de cuartos de cordero y plantas de papa fueron tomadas utilizando una cámara digital.
(Afonso et al., 2019)	Adquisición de 532 imágenes de papa.
(Ibrahim et al., 2020)	Se seleccionaron 100 tubérculos en estado maduro, diferentes en forma, masa y tamaño.
(Siebring et al., 2019)	Adquisición de imágenes VHR que fueron capturadas y procesadas por el Sistema de mapeo hiperspectral.
(Qi et al., 2023)	Recopilación de 240 imágenes sin procesar en un campo experimental con más de 20 genotipos de papa en Danespo Dinamarca.

Tabla 7

Enfermedades, defectos y análisis de la Solanum tuberosum.

Autores	Enfermedad o defecto
(Van De Vijver et al., 2020)	Tizón temprano causado por <i>Alternaria solani</i> .
(Suarez et al., 2022)	Enfermedad del tizón tardío.
(Rashid et al., 2021)	Enfermedad del tizón temprano, enfermedad del tizón tardío.
(Rodríguez et al., 2021)	Enfermedad del tizón tardío.
(Jang et al., 2023)	Estimar la masa de papa para monitorear su rendimiento.
(Zhao et al., 2022)	Detección de las malas hierbas en campos de cultivo.
(Salvador et al., 2020)	Estimación del rendimiento de la papa.
(Shin et al., 2023)	Marchitamiento por <i>Verticillium</i> .
(García et al., 2023)	Enfermedad del tizón tardío.
(Kang et al., 2023)	Enfermedad del tizón temprano, enfermedad del tizón tardío.
(Przybylak et al., 2020)	Tubérculos daños mecánicos y no dañados.
(Oppenheim et al., 2019)	Caspa negra, Caspa plateada, Sarna común, Punto negro.
(Przybyl et al., 2019)	Patata irregular, dañada mecánicamente, Bulbo húmedo de podredumbre, Bulbo seco de podredumbre, Papa por daño mecánico y signos de podredumbre, Tubérculos secundarios desarrollados, Podredumbre y reverdecimiento de la patata.
(Hassoon et al., 2021)	Punto negro, Sarna común, Virus Y, Tizón temprano.
(Yu et al., 2022)	Irregularidad de las papas en su forma.
(Hussain et al., 2021)	Cuartos de cordero (<i>Chenopodium album</i>) en campos de papa.
(Afonso et al., 2019)	Enfermedad de la patata negra.
(Ibrahim et al., 2020)	Calidad de la papa.
(Siebring et al., 2019)	Bacteria <i>Erwinia</i> , Virus PVYNTN.
(Qi et al., 2023)	Enfermedad del tizón tardío.

Tabla 8

Rendimiento de los modelos y métodos de clasificación.

Autores	Rendimiento de los modelos y métodos de clasificación
(Van De Vijver et al., 2020)	PCA + SVM Accuracy: 0.92, PLS-DA Accuracy: 0.89, Decision tree Accuracy: 0.84.
(Suarez et al., 2022)	CNN AUC: 0.97, SVM AUC: 0.87.
(Rashid et al., 2021)	CNN Accuracy 99,75%.
(Rodriguez et al., 2021)	RF (Accuracy:0.842, MCC: 0.714), GBC (Accuracy:0.777, MCC: 0.573), SVC (Accuracy:0.869, MCC: 0.758), L SVC (Accuracy:0.875, MCC: 0.768), KNN (Accuracy:0.806, MCC: 0.645)
(Jang et al., 2023)	Tasa de detección de papa 95,2%.
(Zhao et al., 2022)	MC-YOLOv4 Accuracy: 98.63%.
(Salvador et al., 2020)	RF R-2: 0.839, SVMP R-2:0.858, SVMR R 2:0.837, SVML R-2: 0.863, GLM R-2: 0.834.
(Shin et al., 2023)	Modelo RNN Accuracy: 89%, Modelo ANN pattern recognition Accuracy: 94%.
(Garcia et al., 2023)	Porcentaje de aciertos K-Means 63.52%, Porcentaje de aciertos Hierarchical clustering 68.24%.
(Kang et al., 2023)	CNN Accuracy: 93%.
(Przybylak et al., 2020)	ANN Accuracy: 92%.
(Oppenheim et al., 2019)	CNN Accuracy 96%
(Przybyl et al., 2019)	MLP Accuracy: 97.22%
(Hassoon et al., 2021)	Eficiencia del 91,3%.
(Yu et al., 2022)	Hausdorff (precisión: 0.9423, recall: 0.98 y F1 Score: 0.9608), IoU(precisión: 1, recall: 0.96 y F1 Score: 0.9796).
(Hussain et al., 2021)	GoogleLeNet precision: 0.95, VGG-16 precision: 0.99, EfficientNet-B0 precision: 0.99.
(Afonso et al., 2019)	ResNet18 Accuracy: 94%, ResNet50 Accuracy: 82%.
(Ibrahim et al., 2020)	Tasa de error: 8%.
(Siebring et al., 2019)	RF (F1-Score: 0.75, MCC: 0.47).
(Qi et al., 2023)	2D-CNN (precision: 0.818, recall: 0.938), 3D-CNN (precision: 0.836, recall: 0.929), Random Forest (precision: 0.772, recall: 0.937), PLB-2D-3D-A (precision: 0.878, recall: 0.922).

Figura 2
Artículos por fuente.

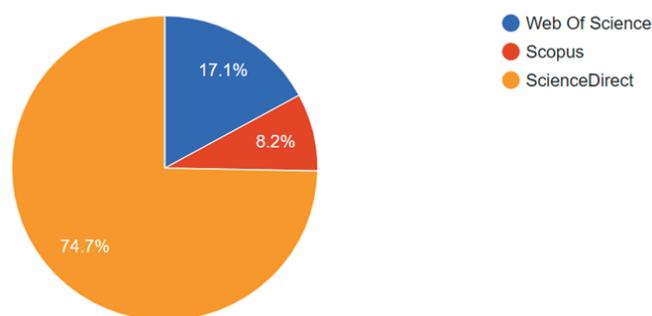


Tabla 9
Artículos por fuente.

Base de datos	Cantidad	%
Scopus	14	8.2
WoS	29	17.1
ScienceDirect	127	74.7

Figura 3

Artículos aceptados por fuente.

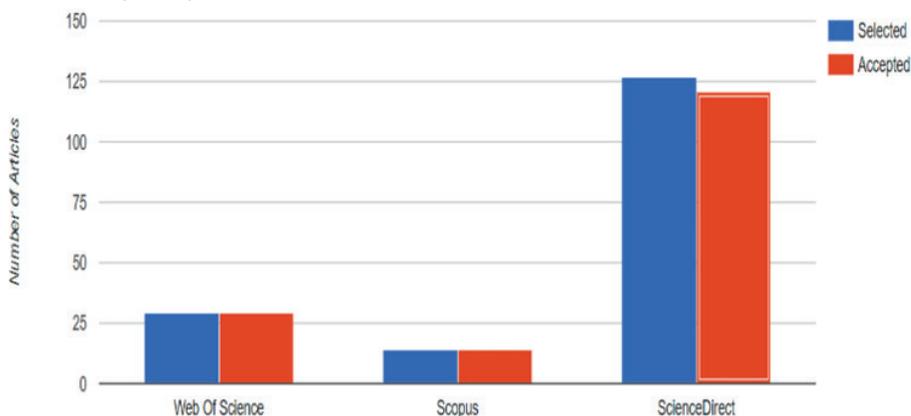
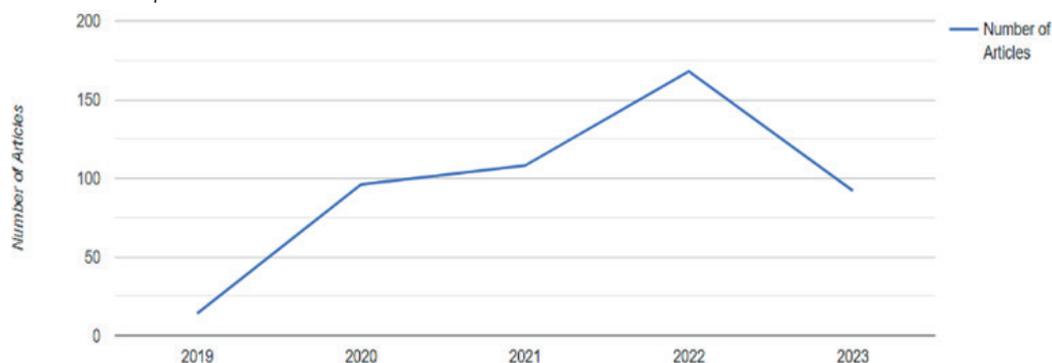


Figura 4

Artículos finales por año.



los modelos de aprendizaje automático en la clasificación de enfermedades y defectos de la *Solanum tuberosum*. Esta revisión es una búsqueda y análisis de artículos académicos publicados en las bases de datos prestigiosas: Scopus, Web Of Science, ScienceDirect, con los cuales se obtuvieron resultados para poder responder a las cuatro preguntas de investigación. Se determinaron los algoritmos usados en las investigaciones para la clasificación de enfermedades y defectos de la *Solanum tuberosum* y se determinaron que los más usados son las Redes Neuronales Artificiales seguido de los algoritmos comunes de machine learning. Se determinó que la recopilación de datos en las investigaciones se realizaron por diversos métodos como imágenes obtenidas mediante prototipo de captura de imágenes de *Solanum tuberosum* de diferentes variedades directamente de los cultivos en regiones específicas, también se determinó que se realizaron captura de imágenes hiperspectrales

y multispectrales haciendo uso de vehículos aéreos no tripulados en campos de cultivo de *Solanum tuberosum*. Con las características de estos datos se contruyeron bases de datos y para ello se utilizaron algoritmos de segmentación de imágenes y extracción de características. Las bases de datos obtenidas fueron utilizadas para la construcción de modelos de clasificación con algoritmos de aprendizaje automático. Se identificaron 15 enfermedades y 9 tipos de defectos de la *Solanum tuberosum*, estas enfermedades afectan drásticamente los cultivos y procesos impactando en su calidad para su consumo y el comercio. En los artículos revisados se determina que en cada uno se construye uno o varios modelos de clasificación y cada uno de estos modelos son optimizados y analizados. En cuanto a la métrica de evaluación del rendimiento de los modelos de clasificación contruidos en las investigaciones, cada uno se detalla con su correspondiente puntuación de calidad.

REFERENCIAS

- [1] Afonso, M. a. (2019). Blackleg detection in potato plants using convolutional neural networks. *IFAC-PapersOnLine*, 52, 6-11. doi:10.1016/j.ifacol.2019.12.481
- [2] Borba, N. (2008). La papa un alimento básico. 1-11.
- [3] Garcia, J., Suarez, M., Junco, E., & Gonzales, J. (2023). Application of unsupervised learning in the early detection of late blight in potato crops using image processing. *INGE CUC*, 18, 89-100. doi:10.17981/ingecuc.18.2.2022.07
- [4] Hassoon, I. M., Qassir, S. A., & Riyadh, M. (2021). PDCNN: FRAMEWORK for Potato Diseases Classification Based on Feed Forward Neural Network. *Baghdad Science Journal*, 18, 1012-1012. doi:10.21123/bsj.2021.18.2(Suppl.).1012
- [5] Hussain, N., Farooque, A. A., Schumann, A. W., Abbas, F., Acharya, B., McKenzie-Gopsill, A., . . . Cheema, M. J. (2021). Application of deep learning to detect Lamb's quarters (*Chenopodium album* L.) in potato fields of Atlantic Canada. *Computers and Electronics in Agriculture*, 182, 106040. doi:10.1016/j.compag.2021.106040
- [6] Ibrahim, A., El-Biale, N., Saad, M., & Romano, E. (2020). Non-Destructive Quality Inspection of Potato Tubers Using Automated Vision System. *International Journal on Advanced Science Engineering Information Technology*, 10, 2419-2428. doi:10.18517/ijaseit.10.6.13079
- [7] Jang, S.-H., Moon, S.-P., Kim, Y.-J., & Lee, S.-H. (2023). Development of Potato Mass Estimation System Based on Deep Learning. *Applied Sciences*, 13, 2614. doi:10.3390/app13042614
- [8] Kang, F., Li, J., Wang, C., & Wang, F. (2023). A Lightweight Neural Network-Based Method for Identifying Early-Blight and Late-Blight Leaves of Potato. *Applied Sciences*, 13, 1487. doi:10.3390/app13031487
- [9] Oppenheim, D., Shani, G., Erlich, O., & Tsror, L. (2019). Using deep learning for image-based potato tuber disease detection. *Phytopathology*, 109, 1083-1087. doi:10.1094/PHYTO-08-18-0288-R
- [10] Przybyl, K., Boniecki, P., Koszela, K., Gierz, L., & Lukomski, M. (2019). Computer vision and artificial neural network techniques for classification of damage in potatoes during the storage process. *Czech Journal of Food Sciences*, 37, 135-140. doi:10.17221/427/2017-CJFS
- [11] Przybylak, A., Kozłowski, R., Osuch, E., Osuch, A., Rybacki, P., & Przygodzinski, P. (2020). Quality evaluation of potato tubers using neural image analysis method. *Agriculture*, 10, 112. doi:10.3390/agriculture10040112
- [12] Qi, C., Sandroni, M., Westergaard, J. C., Sundmark, E. H., Bagge, M., Alexandersson, E., & Gao, J. (2023). In-field classification of the asymptomatic biotrophic phase of potato late blight based on deep learning and proximal hyperspectral imaging. *Computers and Electronics in Agriculture*, 205, 107585. doi:https://doi.org/10.1016/j.compag.2022.107585
- [13] Rashid, J., Khan, I., Ali, G., Almotiri, S. H., AlGhamdi, M. A., & Masood, K. (2021). Multi-Level Deep Learning Model for Potato Leaf Disease Recognition. *Electronics*, 10, 2064. doi:10.3390/electronics10172064
- [14] Rodriguez, J., Lizarazo, I., Prieto, F., & Angulo, V. (2021). Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, 184, 106061. doi:10.1016/j.compag.2021.106061
- [15] Salvador, P., Gomez, D., Sanz, J., & Casanova, J. L. (2020). Estimation of potato yield using satellite data at a municipal level: A machine learning approach. *ISPRS International Journal of Geo-Information*, 9, 343. doi:10.3390/ijgi9060343
- [16] Shin, M.-Y., Viejo, C. G., Tongson, E., Wiechel, T., Taylor, P. W., & Fuentes, S. (2023). Early detection of Verticillium wilt of potatoes using near-infrared spectroscopy and machine learning modeling. *Computers and Electronics in Agriculture*, 204, 107567. doi:10.1016/j.compag.2022.107567
- [17] Siebring, J., Valente, J., Franceschini, M. H., Kamp, J., & Kooistra, L. (2019). Object-based image analysis applied to low altitude aerial imagery for potato plant trait retrieval and pathogen detection. *Sensors*, 19(10.3390/s19245477), 5477.
- [18] Suarez, M., Gomez, A., & Diaz, J. (2022). Supervised Learning-Based Image Classification for the Detection of LateBlight in Potato Crops. *Applied Sciences*, 12, 9371. doi:10.3390/app12189371

- [19] Van De Vijver, R., Mertens, K., Heungens, K., Somers, B., Nuyttens, D., Borra-Serrano, I., . . . Saeys, W. (2020). In-field detection of *Alternaria solani* in potato crops using hyperspectral imaging. *Computers and electronics in agriculture*, *168*, 105106. doi:<https://doi.org/10.1016/j.compag.2019.105106>
- [20] Yu, Y., Jiang, H., Zhang, X., & Chen, Y. (2022). Identifying irregular potatoes using hausdorff distance and intersection over union. *Sensors*, *22*, 5740. doi:10.3390/s22155740
- [21] Zhao, J., Tian, G., Qiu, C., Gu, B., Zheng, K., & Liu, Q. (2022). Weed Detection in Potato Fields Based on Improved YOLOv4: Optimal Speed and Accuracy of Weed Detection in Potato Fields. *Electronics*, *11*, 3709. doi:10.3390/electronics11223709

Fuentes de financiamiento

Propia.

Conflictos de interés

Los autores indican no tener conflicto de interés.