

Visión Artificial en la Identificación de Tomate Maduro para Cosecha Automatizada

Artificial Vision in the Identification of Ripe Tomatoes for Automated Harvesting

Juan Rosales Cortes ^a, José Sergio Ruiz Castilla ^b

Abstract:

In Mexico tomato production has increased. Much of the tomato production is destined for export. The production is grown in greenhouses or protected environments. The density is 6 to 10 plants per square meter inside the greenhouse. Each greenhouses have the capacity from 1000 square meters to several hectares. One person is required for every 1000 square meters to care for the plants. In some regions, there are hundreds of greenhouses. Therefore, hundreds and even thousands of workers are required. As a result, there are not enough workers. An alternative is to implement specialized machinery and equipment for certain tasks within the greenhouse. In this work, it is proposed to create an algorithm for identification of red tomatoes. To cut the tomato it is necessary that they are ripe. In this case the tomatoes, ready to harvest, should be red. Therefore, algorithms have been trained to identify tomatoes with the appropriate red tone. Photographs were taken of green and red tomatoes. Then, the algorithm was trained and classification was carried out. Orange Data Mining was used for training and classification. A result of up to 98% accuracy was obtained. It is concluded that artificial vision algorithms are capable of identifying red tomatoes for cutting. This algorithm is intended to be integrated into a machine to harvest tomatoes as a future project.

Keywords:

Artificial vision, Identification, Tomatoes, Automatized harvesting.

Resumen:

En México la producción de tomate se ha incrementado. Gran parte de la producción de tomate se destina a la exportación. La producción se lleva a cabo en Invernaderos o ambientes protegidos. Cada invernadero hospeda de 6 a 10 plantas por metro cuadrado. Los invernaderos más utilizados tienen la capacidad desde 1000 metros cuadrados hasta hectáreas. Para el cuidado de las plantas, se requiere al menos una persona por cada 1000 metros cuadrados. En algunas regiones, existen cientos de invernaderos. Por lo tanto, se requieren cientos e incluso miles de trabajadores. Como consecuencia, se genera escasez de trabajadores. Una alternativa es implementar maquinaria y equipo especializado para ciertas tareas dentro del invernadero. En este trabajo, se propone crear un algoritmo para identificar tomates maduros. Para el corte del tomate, es necesario que estén maduros. Los tomates maduros, listos para cosechar, deben tener el color rojo. Por lo que, se han entrenado algoritmos para identificar los tomates con el tono rojo adecuado. Para tal fin, se tomaron fotografías de tomates verdes y rojos. Luego se entrenó el algoritmo para realizar la clasificación. Se usó la herramienta Orange Data Mining para el entrenamiento y clasificación. Se obtuvo un resultado de hasta el 98% de precisión. Se concluye que, los algoritmos de visión artificial son capaces de identificar tomates rojos para su corte. Dicho algoritmo se pretende integrar a una máquina para cosechar el tomate como proyecto futuro.

Palabras Clave:

Visión artificial, Identificación, Tomates Cosecha automatizada.

^a Autor de Correspondencia, Universidad Autónoma del Estado de México, <https://orcid.org/0000-0001-7821-4912>, Email: jsruizc@uaemex.mx

^b Universidad Autónoma del Estado de México, <https://orcid.org/0009-0005-5857-1601>, Email: juan.rc19@hotmail.com

Fecha de recepción: 20/10/2025, Fecha de aceptación: 10/03/2026, Fecha de publicación: 05/07/2026

DOI: <https://doi.org/10.29057/xikua.v14i28.16566>



Introducción

Durante el proceso de producción del tomate existen etapas. La primera, consiste en la siembra. La segunda, en el crecimiento de la planta. La tercera, está enfocada en la cosecha de tomate. Las dos primeras etapas requieren un trabajo poco demandante en tiempo y esfuerzo. Sin embargo, en la tercera etapa se requieren trabajadores que corten y transporten las cajas. En dicha etapa, es insuficiente el recurso humano.

La cosecha de tomates es una parte fundamental de la industria agrícola. En el proceso de la cosecha se requiere de eficiencia y precisión, vitales para garantizar la calidad y la rentabilidad del cultivo. Tradicionalmente, la cosecha de tomates ha dependido en gran medida de la mano de obra humana, lo que puede ser costoso y propenso a errores. Sin embargo, en los últimos años, la aplicación de la visión artificial ha revolucionado la forma en que se cosechan los tomates y otros frutos [25]

La agricultura de precisión y la automatización agrícola se han beneficiado significativamente de los avances en inteligencia artificial y aprendizaje automático. La cosecha de tomates maduros es un ejemplo de una tarea agrícola que ha experimentado mejoras sustanciales a través de la inteligencia artificial [24].

El tomate debe cumplir con estándares de calidad, tamaño y color. Por lo que, es pertinente que el recolector conozca dichos estándares. La calidad del producto depende de los estándares cumplidos. Al utilizar procesos automatizados es posible considerar los estándares del producto.

Estado de arte

En el trabajo de Díaz se usó visión artificial. La visión artificial es esencial para detectar la madurez de los tomates y planificar la cosecha. Se han desarrollado algoritmos de detección de objetos que utilizan redes neuronales para identificar tomates maduros y listos para la recolección. También, se debe tomar en cuenta el aprendizaje profundo. Las técnicas de aprendizaje profundo se aplican para mejorar la precisión en la detección de tomates maduros, clasificando con precisión. El objetivo es diferenciar los tomates maduros y otras partes de la planta o el suelo. [1]

La visión artificial es un campo de la inteligencia artificial que se centra en desarrollar algoritmos y sistemas para que las computadoras puedan interpretar, analizar, comprender imágenes y videos. A través de técnicas de procesamiento de imágenes y aprendizaje automático, la visión por artificial permite a las máquinas "ver" y extraer información valiosa de datos visuales. [2]

1. Detección de objetos; Identificar y localizar objetos específicos en una imagen o video, como automóviles, personas, edificios, etc.
2. Clasificación de imágenes; Categorizar imágenes en clases predefinidas, como determinar si una imagen es un gato o un perro.

La visión artificial tiene aplicaciones en una amplia gama de campos, incluyendo medicina, seguridad, automoción, robótica, entretenimiento y más. En este caso, nos enfocaremos en la agricultura, específicamente en la cosecha de tomates rojos. A medida que la tecnología y las técnicas avanzan, se esperan avances significativos en este emocionante campo. [3]

La visión artificial es una rama de la inteligencia artificial que ha permitido la automatización y optimización de la detección de objetos. Con ayuda de cámaras y sistemas de procesamiento de imágenes, se puede integrar un Dataset. El Dataset permite llevar a cabo aplicaciones en el campo de la visión artificial. [4]

En este caso puede detectar y clasificar tomates maduros en tiempo real, asegurando que solo los frutos en su punto óptimo de madurez sean recolectados. Esto no solo mejora la calidad del producto final, sino que también reduce el desperdicio y la dependencia de la mano de obra manual. [5]

Este avance tecnológico ha llevado a la creación de sistemas de cosecha automatizados, como robots y máquinas equipados con sistemas de visión artificial, capaces de realizar tareas de recolección con precisión y eficiencia. Estos sistemas pueden operar en una variedad de condiciones y entornos agrícolas, contribuyendo a la modernización y la sostenibilidad de la industria de la cosecha de tomates. [6]

Otros trabajos revisados se enlistan en seguida. Dichos trabajos están más enfocados a la clasificación de frutas por su madurez, su calidad y forma.

El trabajo de Behera, Rath y Sethy trabajaron la clasificación de la papaya por su madurez. Trabajaron con un Dataset de 300 papayas de las cuales 100 estaban en madurez plena. Aplicaron técnicas de KNN y SVM así como Naive Bayes. Hicieron uso de algoritmos pre-entrenados como: ResNet101, ResNet50, resNet18, VGG19, VGG16 GoogleNet y AlexNet. Sin embargo, los mejores resultados fueron obtenidos con KNN y HOG (Histogram of Oriented Gradients) logrando el 100% de precisión. Usando VGG19 lograron el mismo resultado [7].

En el trabajo de Rizzo y otros en el trabajo tipo "Survey" muestran un análisis de la clasificación de plátanos principalmente. Sugieren que antes de clasificar las frutas es importante considerar: Considerar, el color, textura, brillo entre otras características. Con técnicas de CNN, Árboles de decisión y SVM. Revisan también el uso de técnicas de CNN. Como es un análisis no hay resultados [8].

Por otro lado, Yang y otros desarrollaron un trabajo de clasificación de manzanas de acuerdo con su calidad. En dicho trabajo usaron aprendizaje profundo. La extracción de características se hizo con técnicas de escala de grises y binarización. Con CNN lograron resultados del 99.38% y 99.70% [9].

También, se encontró el trabajo de Harmandeep y Baljit. En dicho trabajo se clasificaron manzanas rojas, verdes y amarillas, guavas (fruta peruana en vaina) y naranjas. Se aplicaron diversas técnicas de procesamiento para extraer mejor las características. Para la clasificación se usaron CNN y RNN como método híbrido. Lograron resultados entre el 95% y el 98.5% [10].

Un trabajo más es de Forhad y otros el cual clasifica mangos usando redes neuronales convolucionales. El objetivo de la clasificación es la calidad. Toman en cuenta, el color, tamaño y la forma. La imagen es segmentada y se hace la extracción de características. A partir de un Dataset de 1400 de 7 categorías de frutas. Se tomaron 180 imágenes para el entrenamiento y otras 20 para la validación. Se usó una CNN con Inception v3 y librerías tales como ImageNet, TensorFlow y Keras. Al final se obtuvieron resultados del 98.74% [11].

Finalmente, el trabajo de Ishikawa y otros en el que se clasifica fresa por su forma. Considerando cuatro tipos de descriptores valores de medidas (MVs), Índice de similitud de la elipse (ESI), Descriptor de Fourier elíptico (EFD) y Substracción del código de cadena (CCS). Para la clasificación se usó Random Forest y SVM. Con resultados muy variados que van desde el 52% hasta el 100% en el indicador de Recall [12]

Tabla 1. Resumen los trabajos relevantes revisados para este trabajo de investigación.

Autores	Proyecto de investigación	Frutas	Técnicas	Precisión
Behera, Rath, & Sethy, 2021	Clasificación de papaya por su madurez	Papaya	CNN	95% al 100%
(Rizzo, Marcuzzo, Zangari, Gasparetto, & Albarelli, 2023	Clasificación de frutas	Plátano	CNN, Árboles de decisión y SVM	A survey
Yang, Kumar, Bhola, & Shabaz, 2022	Clasificación de manzanas por su calidad	Manzanas	CNN	99.70%
(Hermandeep Singh & Baljit Singh, 2021	Clasificación de manzanas	Manzanas	CNN y LSTM	95% al 98.5%
Forhad, Nakib Aman, Julker, & Pritom, 2020	Clasificación de mangos	Mangos	CNN	98%
Ishikawa, y otros, 2018	Clasificación de fresas por su forma	Fresas	Random Forest y SVM	70%

Contexto Teórico

Cultivos protegidos

El cultivo hortícola bajo invernadero es relativamente reducido. El más importante es el tomate, pimiento y melón. Se impone por lo tanto la necesidad imperiosa de que los países mediterráneos diversifiquen sus cultivos protegidos, para mejorar la rentabilidad de las inversiones efectuadas.

El uso más común de un invernadero es para la producción de cultivos hortícolas, es decir, plantas herbáceas, hortalizas de hoja, raíz, tubérculo o fruto. Esto es debido a que la producción bajo condiciones ambientales

controladas contribuye a aumentar la producción de los cultivos. Ver la Figura 1. En la actualidad los cultivos hortícolas que se producen en invernadero en el mediterráneo son: tomate, pimiento, calabacín, melón, pepino, fresa y judía. [13]



Figura 1 Jitomate en invernadero o ambiente protegido [14]

Tomate rojo

El tomate es originario de América del Sur, específicamente de Perú, Ecuador, Bolivia y Chile. Sin embargo, es en México donde se domestica y se le da el nombre de tomate, palabra que proviene del náhuatl compuesta de las "xictli", que significa ombligo, y "tomatl", que significa tomate, es decir tomate de ombligo, es importante mencionar que el nombre científico es "lycopersicum esculentum Mill". El número de días entre la plantación y la cosecha es de 55-65 días en cosecha temprana; de 66 a 80 días de mediana maduración y de mayor maduración de 80 días en adelante. El tomate se clasifica de acuerdo con las siguientes características: (1) forma, (2) madurez y (3) color. Ver la Figura 2.

De acuerdo con su forma, existen 5 tipos, cherry, saladette, tipo pera, bola estándar y bola grande (Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación [SAGARPA], 2010). [15].



Figura 2. Tomates verdes y rojos. Imágenes del Dataset expofreso.

Cosecha de tomate

Los tomates se cosechan a mano, desprendiendo la fruta de la planta al presionar con el dedo pulgar sobre el cáliz o pezón de la fruta, en donde éste se une al pedicelo o pequeño tallo que la conecta a la rama. Ver la Figura 3. Las variedades conocidas como 'jointed' desarrollan una zona de abscisión en el pedicelo, más o menos a mitad de su largo, por lo que frecuentemente el cáliz y parte del pedicelo se quedan adheridos a la fruta al cosecharla. En

el caso de las variedades 'jointless' no se desarrolla la zona de abscisión, y al cosechar la fruta usualmente el cáliz y el pedicelo se quedan adheridos a la planta.



Figura 1. Proceso de corte manual de jitomate [16]

En la mayoría de los mercados se requiere que los cosechadores u otro personal eliminen el cáliz y el pedazo de pedicelo de las frutas que se hayan quedado adheridos a ellas. Por lo tanto, el tiempo dedicado a esta tarea será mayor cuando se cosechan variedades 'jointed' que al cosechar variedades 'jointless', ya que la mayoría de las frutas de estas últimas estarían libres del cáliz y pedicelo. [17]

Inteligencia artificial

La inteligencia artificial (IA) tiene por objeto que los ordenadores hagan la misma clase de cosas que puede hacer la mente. Algunas (como razonar) se suelen escribir como "inteligentes". Otras (como la visión), no. Pero todas entrañan como competencias psicológicas (como la percepción, la asociación, la predicción, la planificación, el control motor) que permite a los seres humanos y demás animales alcanzar sus objetivos. La IA no es una dimensión única, sino un espacio profusamente estructurado de capacidades diversas de procesar la información. Del mismo modo la IA utiliza muchas técnicas diferentes para resolver una gran variedad de tareas. [18]

Herramienta Orange Data Mining

Orange es un software de minería de datos de código abierto que se utiliza para visualizar, analizar y modelar datos.

Orange proporciona una interfaz gráfica de usuario que permite a los usuarios crear flujos de trabajo de minería de datos, arrastrando y soltando widgets en una paleta. Los widgets pueden ser desde una simple tabla de datos, una gráfica, un modelo de aprendizaje automático o incluso una interfaz personalizada.

El software es capaz de realizar tareas como preprocesamiento de datos, clasificación, regresión, clustering, análisis de redes, visualización de datos, y más. También es compatible con muchos formatos de archivo de datos, incluyendo CSV, Excel, SQL y otros. [19]


Algoritmos de clasificación

Redes neuronales

Las redes neuronales tratan de emular el comportamiento del cerebro humano, caracterizado por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos. [20]

Máquinas de Vectores Soporte (SVM)

Es un algoritmo de aprendizaje automático supervisado



que se puede utilizar para problemas de clasificación o regresión. Pero generalmente se usa para clasificar. Dadas dos o más clases de datos etiquetadas, actúa como un clasificador discriminativo, definido formalmente por un hiperplano óptimo que separa todas las clases. Los nuevos ejemplos que luego se mapean en ese mismo espacio se pueden clasificar según el lado de la brecha en que se encuentran. [21]

K-nearest neighbors (KNN)

El algoritmo de las K vecinas más cercanas o K-nearest neighbors (KNN) es un algoritmo de Machine Learning que pertenece a los algoritmos de aprendizaje supervisado simples y fáciles de aplicar que pueden ser utilizados para resolver problemas de clasificación y de regresión.

En contraste con otros algoritmos de aprendizaje supervisado, KNN no genera un modelo fruto del aprendizaje con datos de entrenamiento, sino que el aprendizaje sucede en el mismo momento en el que se prueban los datos de prueba. [22]

Regresión logística

La regresión logística resulta útil para los casos en los que se desea predecir la presencia o ausencia de una característica o resultado según los valores de un conjunto de predictores. Es similar a un modelo de regresión lineal, pero está adaptado para modelos en los que la variable dependiente es dicotómica. Los coeficientes de regresión logística pueden utilizarse para estimar la razón de probabilidad de cada variable independiente del modelo. La regresión logística se puede aplicar a un rango más amplio de situaciones de investigación que el análisis discriminante [23].

Metodología

La metodología propuesta se muestra en la Figura 4. Se trata de un diagrama de flujo que muestra las etapas para la obtención de resultados.

Figura 4. Diagrama de flujo del Método tentativo

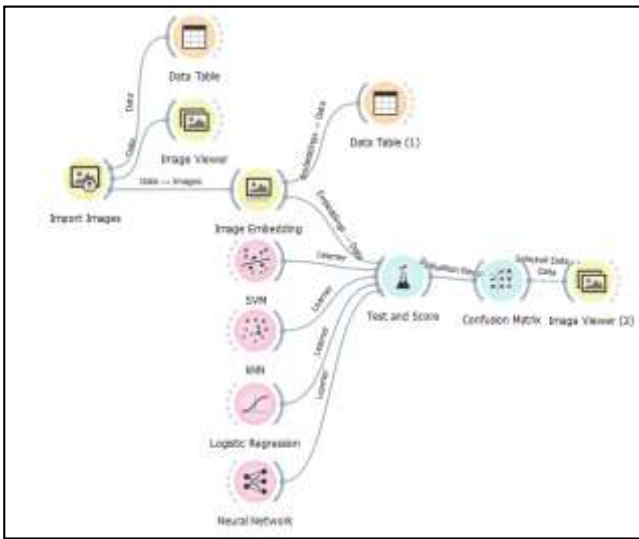
El método tentativo muestra los siguientes pasos principales:

Obtención de imágenes. Fueron obtenidos desde un celular o desde una cámara profesional. Se esperan obtener al menos 300 imágenes.

Creación del Dataset. El Dataset tiene un conjunto de tomates verdes y otro de tomates rojos.

Etapas de entrenamiento. Se entrenó la red usando herramientas tales como Orange o librerías como Tensor Flow.

Etapas de clasificación. Se aplicaron clasificadores para



La herramienta de Orange nos proporciona detalles del Dataset. Orange hace una extracción de características de cada imagen. Las características más comunes son: El tamaño, el ancho y largo de cada imagen. Además de la categoría de Verdes y Rojos. Ver la Tabla 2. También, Orange extrae múltiples características que etiqueta de forma automática como N0, n1, n2, etc. Almacena valores normalizados que se usarán durante la clasificación. En este caso para la clasificación utiliza un vector de valores enteros o fraccionarios que pueden ser procesados por los clasificadores. Ver la Tabla 3

200	Rojos	Rajo5	Rojosrojo 5.jpg	2986940	3000	4000
201	Rojos	Rajo6	Rojosrojo 6.jpg	2971638	3000	4000
202	Rojos	Rajo7	Rojosrojo 7.jpg	3267032	3000	4000
203	Rojos	Rajo8	Rojosrojo 8.jpg	2838703	3000	4000
204	Rojos	Rajo9	Rojosrojo 9.jpg	2918643	4000	4000
205	Verdes	Verde1	Verdes\verde1.jpg	3690707	3000	4000

encontrar el mejor algoritmo para este caso.

Obtener resultados. Se obtuvieron resultados de la clasificación después de hacer los ajustes de parámetros pertinentes.

Evaluar los resultados. Se aplicaron métricas de evaluación de resultados tales como la Matriz de confusión y área bajo la curva.

El proyecto forma parte de la implementación de una máquina cosechadora de tomate. Dicha máquina deberá ubicar el tomate maduro y cortarlo. Se muestra una imagen tentativa de la máquina en la Figura 5.



Figura 5. Esquema de la máquina cosechadora de tomate.

Modelo en Orange Data Mining

En la Herramienta de Orange se configuró un modelo. Ver la Figura 6. El modelo presentado es que dio los mejores resultados. En dicho modelo se eligieron los clasificadores: SVM, KNN, Regresión logística y Red neuronal. Mientras que se usó la matriz de confusión para conocer los detalles de los resultados.

Figura 6. Modelo usado en la Herramienta de Orange.

Tabla 2. Modelo usado en la Herramienta de Orange.

Hid den Origin	Categ ory	Image Name	Image DATASET S/Dataset Jitomate/i mage	Size	Width	Heigh t
----------------	-----------	------------	---	------	-------	---------

206	Verdes	Verde2	Verdes\verde2.jpg	4147472	3000	4000
207	Verdes	Verde3	Verdes\verde3.jpg	3636914	3000	4000
208	Verdes	Verde4	Verdes\verde4.jpg	3550376	3000	4000
209	Verdes	Verde5	Verdes\verde5.jpg	3687784	3000	4000
210	Verdes	Verde6	Verdes\verde6.jpg	3425376	3000	4000
211	Verdes	Verde7	Verdes\verde7.jpg	3578084	3000	4000

Tabla 3. Modelo usado en la Herramienta de Orange.

Hid den Origin	n0 true	n1 true	n2 true	n3 true	n4 true
200	0.338753	0.142896	0.421595	0.42069	0.92813
201	0.433291	0.0266792	0.367053	0.220706	0.14195
202	0.407917	0.108427	0.044167	0.334333	0.38423
203	0.459214	0.149617	0.776627	0.088767	0.13826
204	0.121906	0.0077965	0.646442	0.37613	0.39614
205	0.115213	0.0144452	0.740741	0.26614	0.31618
207	0.172686	0.980539	0.384766	0.040535	0.13476
208	0.189365	0.030637	0.31538	0.258541	0.23718
209	0.195876	0.022388	0.379188	0.245799	0.27611
210	0.232697	0.293895	0.615934	0.116386	0.32385
211	0.359284	0.0282745	0.32736	0.118688	0.27271

Para el proceso de extracción y entrenamiento es necesario elegir un algoritmo. La Herramienta permite elegir entre: Inception v3, SqueezeNet, VGG16, VGG 19, Painters, DeepLoc y openface. En este caso se eligió Inception v3, porque proporcionó mejores resultados.

Se ajustaron parámetros del algoritmo KNN, definiendo 4 datos vecinos basados en la distancia. En el caso de la SVM se definió el Costo en 3.6 y la pérdida de epsilon de la regresión en 2.5. Mientras que para la regresión logística se estableció como nivel 2 (L2) para la Cresta (ridge). Finalmente, para la Red neuronal se ajustó a 158 neuronas en la capa oculta y 276 iteraciones.

Resultados

Una vez entrenado el algoritmo se obtuvieron resultados. Los resultados muestran una precisión de hasta el 98.3%. El mejor resultado fue obtenido desde regresión logística, mientras que en la revisión más baja fue del algoritmo de kNN. Los parámetros usados fueron 10 en la validación cruzada (number of folds), El número de repeticiones de entrenamiento fue de 100. Además de, hacer el entrenamiento con el 80% de muestras y 20% para la

validación. Tabla 4.

Tabla 4. Resultados obtenidos de los clasificadores

Model	AUC	CA	F1	Prec	Recall	MCC
SVM	0.999	0.980	0.988	0.988	0.988	0.954
kNN	0.993	0.957	0.957	0.958	0.957	0.903
Regresión logística	0.999	0.983	0.983	0.983	0.983	0.962
Red neuronal	0.988	0.967	0.967	0.970	0.967	0.928

Para conocer mejor los resultados se usó la matriz de confusión de cada categoría clasificada. Las siglas usadas significan: VP (verdaderos positivos), FP (Fasos positivos), FN (falsos negativos) y VN (verdaderos negativos). Tabla 5.

Tabla 5. Matriz de confusión de los cuatro clasificadores

Clasificador	VP	FP	FN	VN
SVM	201	3	3	92
kNN	194	10	3	92
Regresión logística	201	3	2	93
Red neuronal	194	10	0	95

Conclusiones

En resumen, la implementación de la IA en la cosecha de tomates rojos ofrece una serie de ventajas significativas en términos de eficiencia, calidad del producto y reducción de costos laborales. A medida que la tecnología continúa evolucionando y superando los desafíos, es probable que su adopción se generalice aún más en la industria agrícola, lo que contribuirá a la mejora de la producción de alimentos y la sostenibilidad. El algoritmo entrenado puede incorporarse a una máquina diseñada para la cosecha automatizada. La máquina con el algoritmo integrado deberá moverse identificando tomates rojos y cortarlos.

Referencia

- [1] J. V. E. Ramos-Díaz, Algoritmo integrado con inteligencia Artificial apoyado en mano robótica para el reconocimiento de la madurez del tomate, Lima, Peru: Universidad Peruana Unión, 2020.
- [2] E. Tapia Méndez, Sistema de alerta del estado de maduración de alimentos frescos dentro de un refrigerador utilizando inteligencia artificial utilizando inteligencia artificial, Queretaro: UAQ, 2023.
- [3] I. & C. V. García, «La visión artificial y los campos de aplicación.» Tierra Infinita, 2015. pp. 98-108.
- [4] J. V. Martínez-Mellado, Creación de un dataset para detectar la tos mediante imagen, Alicante: Universidad de Alicante, 2021.
- [5] G. J. Arzate C., B. González H. y A. Sánchez D., Metodología Para la Clasificación de Tomates por medio de procesamiento de imágenes con base en la norma NMX-FF-031-1997, CDMX: IPN, 2017.
- [6] J. F. Sotomayor, P. G. Gómez y A. F. Cela, «Sistema de Visión Artificial para el Análisis de Imágenes de Cultivo basado en Texturas Orientadas.» Revista Politecnica, [Accessed: 1/Febrero/2014].
- [7] S. K. Behera, A. K. Rath y P. K. Sethy, «Maturity status classification of papaya fruits based on machine learning and transfer learning approach.» Infroamtion Preccessing in Agriculture, 2021. pp. 244-250.
- [8] M. Rizzo, M. Marcuzzo, A. Zangari, A. Gasparetto y A. Albarelli, «Fruit ripeness classification: A survey.» Artificial intelligence in Agriculture, 2023. pp. 44-57.
- [9] M. Yang, P. Kumar, J. Bhole y M. Shabaz, «Development of image recognition software based on artificial intelligence algorithm for the efficient sorting of apple fruit.» Int J Syst Assur Eng Manag, 2022. pp. 322-330.
- [10] G. Hermandeep Singh y K. Balgit Singh, «Hybrid classifier model for fruit classification.» Multimedia Tools and Applications, 2021. pp. 27495-27530.
- [11] A. Forhad, T. Nakib Aman, N. Julker y S. Pritom, «Fruits Classification using Convolutional Neural Network.» Global Research and Development Journal for Engineering, 2020. pp. 1-6.
- [12] T. Ishikawa, A. Hayashi, Y. Kyutoku, I. Dan, T. Wada, K. Oku, Y. Saeki, T. Uto, T. Tanabata y S. ISOBE, «Clasificación os strawberry fruit shape by machine learning.» The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2018. pp. 463-470.
- [13] Novagric, «Novagric.» [Online]. Available: <https://www.novagric.com/es/blog/articulos/cultivos-invernadero-hortalizas>. [Accessed: 24/Noviembre/2015].
- [14] Gobierno-del-Estado-de-Hidalgo, «Gobierno del estado de Hidalgo 2022-2024.» [Online]. Available: <https://2016-2020.tulancingo.gob.mx/jitomate-que-se-siembra-en-tulancingo-se-consume-en-estados-unidos-canada-y-centroamerica/>. [Accessed: 12/enero/2024].
- [15] M. T. Álvarez Medina, M. A. Núñez Ramírez y T. R. WendLandt Amezaga, «TheIBFR.» [Online]. Available: <https://delivrypdf.ssrn.com/delivery.php?ID=355025009087122075126009095119072067014057084078086094127025006100031107068074104002097006055007116104052101080088027082029002112073005049029104105105120103001025011081092067024111083083070067023126096123006070>. [Accessed: 2/marzo/2017].
- [16] GCM, «Granjas Carroll S. de R. L.» [Online]. Available: <https://granjascarroll.com/invernadero-de-jitomate-que-apoya-gcm-beneficia-a-54-familias-en-xaltipanapa/>. [Accssed: 11/noviembre/2024].
- [17] G. J. Fornaris, «Cosecha y Manejo de postcosecha.» [Online]. Available: <https://www.upr.edu/eea/wp-content/uploads/sites/17/2016/03/TOMATE-Cosecha-y-Manejo-Postcosecha-v2007.pdf>. [Accessed: 17/marzo/2007].
- [18] M. A. Boden, Inteligencia Artificial, Madrid: Coleccion Noema, 2017.
- [19] Orange, «Orange.» [Online]. Available: <https://orangedatamining.com/docs/>. [Accessed: 19/ Septiembre/2023].
- [20] R. Flores López y J. M. Fernández Fernández, Las Redes Neuronales Artificiales, España: netbiblo, 2008.
- [21] E. C. León, «core.ac.uk.» [Online]. Available: <https://core.ac.uk/download/pdf/289986621.pdf>. [Accessed: 13/diciembre/2023].
- [22] S. Valero Orea, A. Salvador Vargas y M. García Alonso, «cloudfront.» [Online]. Available: https://d1wqtxts1xzle7.cloudfront.net/34203825/e1-libre.pdf?1405405787=&response-content-disposition=inline%3B+filename%3DMineria_de_datos_prediccion_d_e_la_deserc.pdf&Expires=1697063090&Signature=FcE5MrFCIJTvKMr9brnTWvocfdHIAagaOmaKwMoIn78JEEmmSCrg5WdB~yb. [Accessed: 10/Enero/2005].
- [23] IBM, «IBM Documentacion.» [Online]. Available: <https://www.ibm.com/docs/es/spss-statistics/saas?topic=regression-logistic>. [Accessed: 04/agosto/2023].
- [24] J. Restrepo-Arias, «Método de clasificación de imágenes, empleando técnicas de inteligencia artificial, integradas en una plataforma IoT de agricultura inteligente.» Repositorio institucional, Universidad Nacional de Colombia, p. 147 páginas, 2023.
- [25] F. Casierra Posada y O. E. Aguilar Avendaño, «Calidad en frutos de tomate (Solanum lycopersicum L.) cosechados en diferentes estados de madurez.» Scielo, 10/julio/2008.