UNIVERSIDAD SEÑOR DE SIPÁN

Facultad de Ingeniería, Arquitectura y Urbanismo

Escuela Académico Profesional de Ingeniería de Sistemas

INFORME DE INVESTIGACIÓN

CLASIFICACIÓN NO DESTRUCTIVA DE FRUTAS UTILIZANDO INTELIGENCIA ARTIFICIAL: REVISIÓN BIBLIOGRÁFICA

Autor:
Olano Chávez Wilfredo Cristóbal

Asesor:
Mg. Tuesta Monteza Víctor Alexci

Línea de Investigación:
Ingeniería Tecnología y Urbanismo

Sub Línea de Investigación:
Ciencias de la Computación

Pimentel - Perú

2019

DEDICATORIA

A Dios por la dicha de tener una familia maravillosa.

A mis padres Eleuterio Olano Zulueta y Emilia Chávez Saldaña por su infinito amor. Gracias por siempre estar pendiente de mi en todo momento, especialmente en los difíciles, así como por apoyar todas las decisiones que he tomado. Los Amo con todo mi ser.

A mi hermano Kelvin Olano Chávez por demostrarme su grandeza cada día de mi vida por ser mi orgullo y mi bendición, se que vas a cumplir todos tus sueños y algún día serás un gran ingeniero. Te Amo hermano.

A mi hermana Florita Olano Chávez por ser mi amiga y mi madre a la vez y a mis amigos y hermanos Ivan y Nancy por sus consejos y apoyo gracias totales.

AGRADECIMIENTOS

"Si he visto más lejos

es porque estoy sentado

sobre los hombros de gigantes."

- Isaac Newton

Agradezco a los ingenieros del laboratorio de ciencia de la computación de la Universidad Libre Seccional Calí por todo su apoyo. Así mismo, a mis amigos del laboratorio visión multimedia de la Universidad del Valle Calí y a los docentes del laboratorio BIOSIS de la Universidad Señor de Sipán, gracias totales.

RESUMEN

Los últimos avances sobre visión artificial permiten una variedad de aplicaciones en diferentes campos cotidianos de la vida, una de estas disciplinas es la clasificación de frutas experimentando un gran porcentaje de acierto dependiendo de las variables a controlar, si bien es cierto se avanzado de manera constante todavía sigue siendo un campo de investigación abierto ya que está demostrado que garantizar la calidad de este procedimiento supone un problema complejo y necesita ser desarrollado. La clasificación de frutas presenta retos significativos debido a las similitudes entre clases y las características irregulares que existe en cada una de estas; es por ello que la selección de los componentes para la extracción de los datos apropiados y el debido enfoque de representación de las características es considerado decisivo en éxito o fracaso del método planteado. Se han desarrollado métodos para evaluar la calidad de las frutas utilizando componentes robóticas con la limitación de que estas se vienen desarrollando bajo conjunto de datos limitados o sumamente controlados. El problema en el cual convergen las propuestas es que la clasificación natural de las frutas es multidimensional y ofrece características de las muestras significativamente diferentes, lo que constituye un gran desafió para los enfoques de aprendizaje automático. Se han llevado a cabo investigaciones sustanciales para el diseño y análisis de clasificadores de estas características mencionadas las cuales generalmente requieren un soporte computacional significativo. Así mismo, en los últimos 9 años se han realizado numerosas técnicas de aprendizaje de máquinas tales como, Árboles de decisión, Maquinas de vectores de soporte (SVM), k-vecinos más cercanos (k-NN), Redes neuronales artificiales (ANN), Redes neuronales convolucionales (CNN) y Algoritmos Fuzzy, utilizado diferentes métodos para el proceso de clasificación de las frutas.

Palabras Clave— Inteligencia artificial, aprendizaje automático, automatización, clasificación de frutas, extracción de características, segmentación, color, forma, textura

ABSTRACT

The latest advances in artificial vision allow a variety of applications in different fields of daily life, one of these disciplines is the classification of fruits experiencing a large percentage of success depending on the variables to be controlled, although it is true that constant progress is still an open field of research as it is proven that ensuring the quality of this procedure is a complex problem and needs to be developed. The classification of fruits presents significant challenges due to the similarities between classes and the irregular characteristics that exist in each of these; it is for this reason that the selection of the components for the extraction of the appropriate data and the due approach of representation of the characteristics is considered decisive in success or failure of the proposed method. Methods have been developed to evaluate fruit quality using robotic components with the limitation that these are being developed under limited or highly controlled data sets. The problem on which the proposals converge is that the natural classification of fruits is multidimensional and offers significantly different sample characteristics, which is a great challenge for automatic learning approaches. Substantial research has been conducted for the design and analysis of classifiers of these characteristics which generally require significant computational support. Likewise, in the last 9 years numerous machine learning techniques have been performed such as, Decision Trees, Support Vector Machines (SVM), Nearest Neighbours (k-NN), Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN) and Fuzzy Algorithms, using different methods for the fruit classification process.

Keywords— Artificial intelligence, machine learning, automation, fruit classification, feature extraction, segmentation, color, shape, texture

ÍNDICE GENERAL

Pag.

DEDICATORIA 1

AGRADECIMIENTOS 2

RESUMEN 1

ABTRACT 2

ÍNDICE GENERAL 3

ÍNDICE DE FIGURAS 4

ÍNDICE DE TABLAS 5

LISTA DE ABREVIATURAS O SIGLAS 6

1. INTRODUCCIÓN 7

1.1 Antecedentes de estudio 8
1.2 Planteamiento del problema de investigación 14
1.3 Objetivos. 14
1.3.1 Objetivo general 14
1.3.2 Objetivos específicos 14
1.4 Marco teórico conceptual 15
1.4.1 Fundamentos clasificación automatizada 15
1.4.1.1 Dispositivos para la extracción de datos 15
1.4.1.2 Características 16
1.4.1.3 Modelo de color 16
1.4.1.4 Entornos automatizados 17
1.4.2 Procesos para la clasificación automatizada 17
1.4.2.1 Extracción de datos 18
1.4.3 Preprocesamiento de los datos 18
1.4.3.1 Preprocesamiento 18
1.4.3.2 Segmentación 19
1.4.4 Extracción de características 19
1.4.4.1 Descriptores de características de forma 20
1.4.4.2 Chain Code 20
1.4.4.3 Descriptores de la característica de textura 21

1.4.4.4 Descriptores de características de color 21
1.4.5 Clasificación 22
1.4.5.1 Algoritmos de clasificación 23

2. MÉTODO DE INVESTIGACIÓN 27

2.1 Plan de la investigación 28
2.1.1 Interrogantes de la investigación 28
2.1.2 Protocolo de revisión 28
2.1.3 Validar Protocolo de revisión 30
2.2 Procedimiento de la investigación 30
2.2.1 Identificar las investigaciones relevantes 30
2.2.2 Seleccionar los estudios primarios 32
2.2.3 Evaluar la calidad de los estudios 34
2.2.4 Extraer datos requeridos 35
2.2.5 Sintetizar los datos 35
2.3 Documentación dela investigación 58
2.3.1 Validar el informe 58

3. RESULTADOS 59

3.1 Análisis 60

4. CONCLUSIONES 70

4.1 Limitaciones 70

REFERENCIAS 122

ÍNDICE DE FIGURAS

FIGURA Pag.

1.1 Procesos para la Clasificación Automatizada de Frutas 18

1.2 Los códigos utilizados: (a) Direcciones F8, (b) Direcciones relativas AF8 21

1.3 cambios en las imágenes digitales (reflectancia) 22

2.1 Método de revisión bibliográfica 27

2.2 Resultado del filtro de la plataforma SCImago Journal & Country Rank 30

2.3 Resultado crudo de la búsqueda IEEE 31

2.4 Valoración de los artículos 58

3.1 Cantidad de artículos por año aplicando el filtro crudo tal cual arroja la regla de búsqueda 59

3.2 Tendencia de la cantidad de publicaciones de los artículos aplicando el filtro final según el protocolo de revisión 63

3.3 Selección de los algoritmos de clasificación 67

ÍNDICE DE TABLAS

TABLA Pag.

1.1 Clasificación de los modelos de color 17

1.2 Pseudocódigo del algoritmo k-NN 23

1.3 Pseudocódigo del algoritmo árbol de decisión 24

2.1 Búsqueda de base de datos y resultados 31

2.2 Resumen de las propuestas planteadas desde el 2010 - 2018 33

2.3 Resumen de impacto de las revistas (2011-2019) 35

3.1 Resultados mas significativos sobre clasificación automatizada de frutas, 2010 - 2018 62

3.2 Cantidad de artículos publicados sobre clasificación automatizada de frutas entre el año 2010 - 2018 62

3.3 Análisis de rendimiento de los algoritmos de clasificación 68

LISTA DE ABREVIATURAS O SIGLAS

CIE L*a*b* Lightness, A(Green-Red), B (Blue-Yellow). 69

HSI Hue, Saturation, Lightness. 9, 10, 69

HSV Hue, Saturation, Value. 10

k-NN K-Nearest Neighbor. 23, 67

PNN Red Neural Probabilistic. 11

RF Random Forest. 24

RGB Read Green Blue. 8–10, 67

RNA Red Neuronal Artificial. 23, 25, 67

ROI Region of Interest. 19

SVM Support Vector Machine. 10, 23, 25, 67

1. INTRODUCCIÓN

Hoy en día son muchas las aplicaciones de vida real en donde se encuentra inmerso la inteligencia artificial por destacar alguna de estas son traductores inteligentes, reconocimiento facial, robots con capacidades de aprendizaje automático, entre otras. Todas estas se centran en intentar modelar las capacidades del cerebro del ser humano al intentar describir ciertas acciones. En consecuencia, las frutas representan un porcentaje importante en las economías del mundo es por ello que se busca mejorar todos los procesos desde la evaluación de las semillas hasta llegar al cliente considerando las exportaciones y uno de los más importantes es la clasificación según ciertos parámetros para asegurar la calidad del producto. Usualmente es en este punto en donde surge el principal problema ya que los productos son seleccionados manualmente bajo la perspectiva del ojo experto del ser humano en cuanto a la calidad o cultivo lo cual supone serios inconvenientes relacionadas al experto como por ejemplo la excesiva concentración por tiempo prolongados para mantener la consistencia, así mismo se debe familiarizar con muchas características de producto lo cual puede conllevar a distintas interpretaciones generando una clasificación desigual afectando de forma directa la calidad del proceso de clasificación [1, 2, 3, 4]. La industria agrícola hoy en día generalmente aplica mecanismos industriales para realizar la clasificación basándose en la fusión de componentes robóticas con modelos de visión por computador el cual analiza ciertos patrones en las características de las frutas para realizar este procedimiento generando un gran acierto en beneficio de calidad del proceso [5]. La visión por computador es un campo de análisis matemático de datos visuales en términos de imágenes de todo tipo y esto puede ser una tarea desafiante cuando se aplica a cualquier campo [6]. Los datos visuales de las frutas generalmente son imágenes binarias que luego son expandidas a imágenes hiperespectrales [7], esta práctica es considerada como la más significativa e importante en cuanto a visión computarizada de los datos generando una especie de estándar emergente en muchísimas aplicación en frutas [1, 8].

En la industria agrícola, uno de los requisitos más importantes de la visión por computador es una técnica no destructiva para la evaluación de la calidad, la clasificación automatizada y la cosecha robótica [9]. La clasificación de las frutas es un problema complejo debido a un sin número de variables que se deben considerar en diferentes características como pueden ser la forma, el color, el tamaño y la textura [10]. Se debe agregar que todas estas presentan irregularidades en cuanto a su contenido complicando el procesamiento de similitudes. Estas limitaciones han causado una falta de sistemas inteligentes automatizados para la clasificación de frutas considerando múltiples características de forma eficiente. Además, un sistema automatizado de clasificación de frutas resulta ser muy útil al momento de ofrecer alternativas al momento de escoger un producto adecuado con ciertas características, también podría resultar útil para personas con discapacidad visual, etc. Hay que mencionar, además que en los últimos avances en este campo son una combinación de datos que describen ciertas características y algoritmos de aprendizaje automático [11]. Al día de hoy se han publicado investigaciones relevantes relacionadas con el tema en cuestión utilizando distintas características antes mencionadas. A pesar de ser un campo bastante explorado debido a su enorme significado hacia las economías de los países de mundo todavía sigue siendo un campo de investigación abierto ya que es necesario superar muchos desafíos para poder garantizar un sistema eficaz de clasificación de frutas. En consecuencia, el presente documento ofrece un estudio bibliográfico de las propuestas planteadas en cuanto al procedimiento mencionado.

1.1 Antecedentes de estudio

[1] Mencionan que la inspección de calidad para la exportación de fruta carambola todavía se realiza manualmente por el trabajo humano hasta hoy. Debido al proceso manual, en esta propuesta se desarrolla una adaptación de un proyecto anterior el cual se trabajo bajo el componente RGB, se propuso un sistema en tiempo real para la inspección de madurez del color de la fruta de la carambola, para ello se obtuvo las imágenes de muestra con una cámara comercial CCD la cual obtiene imágenes en el espacio de color RGB las cuales se transformaron

al espacio color YCbCr finalmente se realizo la clasificación utilizando los componentes Cb y Cr. El resultado de la propuesta es del 96% de precisión.

[12] propusieron un algoritmo para la selección y clasificación de las frutas de limón basado en las características de color y tamaño utilizando el lenguaje Visual Basic 6. Se calculo el volumen de la imagen de muestra, asimismo, las imágenes RGB se convirtieron en imágenes HSI. Además, se estimaron los valores de HSI y estos datos se almacenaron en una base de datos. Finalmente se realizo la clasificación para ello el volumen y el color se comparo con la información guardada en la base de datos, se obtuvo una precisión del 94,04%.

[13] presentaron un sistema para la clasificación automática de la fresa. Se utilizo el procesamiento de imágenes el primer paso que se llevo acabo es convertir la imagen del modelo RGB a al modelo de color L*a*b*. Además, se calculó el tamaño utilizando la longitud del eje principal y las características de color se extrajeron del modelo de color dominante en un canal a*. Se utilizó el método de agrupación k-Means para realizar la clasificación. Se obtuvo una precisión de 90% para la clasificación de la forma y del 88,8% para la el color.

[14] presentaron un enfoque novedoso para realizar la clasificación de las frutas de. En este trabajo se analizaron cinco frutas (manzanas, plátanos, zanahorias, mangos y naranjas). Las extrajeron características de forma y color de las imágenes correspondientes a las muestras de frutas. Luego se utilizaron características morfológicas para distinguir entre formas y tamaños casi similares, como manzana y naranja o plátanos y zanahorias. Se utilizo características de color para eliminar la clasificación errónea entre manzana y naranja o plátano y zanahoria y aumentar la precisión a 79-90%.

[15] realizo un experimento para clasificar cinco tipos diferentes de imágenes de frutas (manzana, chikoo, naranja, mango y limón dulce). En total se capturaron 5000 imágenes de muestra, es decir, 1000 imágenes de cada tipo de fruta. Se desarrollo un algoritmo extrayendo 18 color y 27 características de textura. Las características de color se calcularon separando los componentes RGB (rojo, verde y azul). La imagen RGB fue convertida al modelo HSI y sus componentes fueron separados. La media, la varianza y el rango se calcularon para cada

componente RGB y HSI individualmente. Las características de la textura fueron calculadas usando Matrices de Co-ocurrencia de Nivel Gris (GLCM). El estudio reveló que la clasificación del chikoo, la manzana, el limón dulce, la naranja y el mango es 94%, 93%, 93%, 92% y 92% respectivamente.

[16] propuso un sistema de clasificación de las frutas de Mozafati. Se tomaron 100 frutas en total y se calcularon tres parámetros de calidad, como la cantidad de zumo, el calibre y la frescura. Estas frutas fueron calificadas usando tanto el sistema de interferencia difusa como expertos humanos para la comparación y calificadas usando el sistema difuso mostraron un resultado de conformidad del 86% en comparación con los expertos humanos.

[17] presentaron una clasificación automática de las manzanas con la ayuda de máquinas vectoriales de soporte (SVM). En este caso, las imágenes de manzana se capturaron en el modelo de color RGB y se utilizó la segmentación basada en umbrales para extraer la región de interés del fondo. El modelo de color RGB se convirtió entonces en un modelo HSV y se determinaron los componentes de color rojo y verde promedio para su clasificación. Este clasificador proporcionó una precisión del 100% en la clasificación.

[18] presentaron la clasificación automática del mango usando análisis difuso. En este tamaño, se extrajeron el color y las características de la piel. El tamaño del mango se determinó calculando el área de la imagen de muestra. Luego se extrajo el componente RGB de la imagen y se detectó la media de tres componentes de color. Para el análisis de la forma, se había implementado un algoritmo de detección de bordes. Se aplicaron reglas de inferencia difusa para la clasificación del mango en diferentes clases y se obtuvo una precisión general del 80%.

[19] propuso un nuevo método para diferenciar el extremo del tallo de la manzana/cáliz del defecto verdadero de acuerdo con su información de profundidad en la superficie de la manzana. El proyector fue diseñado para generar luz estructurada NIR basada en la codificación de posición. La luz estructurada NIR se utilizó para detectar la información de profundidad de la superficie de la manzana, y luego se identificó la región del extremo del tallo y el cáliz.

Dio una tasa global de detección del 95,24%.

[20] propuso un método para evaluar las características extraídas utilizadas para la clasificación de frutos defectuosos y no defectuosos. La base de datos de imágenes incluía 200 frutas de mosambi. Se calcularon las características de forma, intensidad y textura. Esta base de datos fue entonces clasificada con base en PNN y el resultado mostró que las características de forma, intensidad y textura dieron una tasa de identificación del 100%, 92% y 96% respectivamente.

[21] expone que la automatización de la clasificación de frutas es una aplicación interesante de la visión por ordenador. Las estrategias de visión por computadora utilizadas para clasificar una fruta según la intensidad, el color, la forma y la textura. Este artículo propone una técnica tradicional que utiliza la característica de color y textura para la clasificación de la fruta. El método tradicional de clasificación de frutas depende de la operación manual basada en la habilidad visual. La clasificación se realiza mediante el clasificador de la Máquina de vectores de soporte (SVM) según las características estadísticas y de ocurrencia derivadas de la transformada wavelet. La precisión de clasificación para el sistema propuesto es del 95,3%.

[22] menciona que la clasificación automática de las frutas es un problema difícil porque hay muchos tipos de frutas y la gran similitud entre las clases. En este estudio, propusimos utilizar una red neuronal convolucional (CNN) para la clasificación de la fruta. Diseñamos una CNN de seis capas que consta de capas de convolución, capas combinadas y capas totalmente conectadas. Los resultados del experimento sugirieron que nuestro método logró un rendimiento prometedor con una precisión de 91.44%, mejor que tres enfoques de vanguardia: máquina de vectores de apoyo basada en la votación, entropía wavelet y algoritmo genético.

[23] proponen un método basado en la visión artificial sin contacto para estimar el nivel de madurez de la fruta de guayaba. La fruta sometida a prueba se clasifica como verde, madura, demasiado madura y estropeada utilizando un sistema de visión por computadora basado en una cámara web. Este método simple utiliza una combinación de cámara web digital; Computadora y software basado en GUI desarrollado en forma indígena para medir y analizar el color de

la superficie de las frutas. Las imágenes de la fruta bajo prueba se capturan y se muestran en la pantalla de la computadora. Se calcula la información cuantitativa, como la distribución de color RGB, los valores triestímulos basados en el estándar CIE1931, las coordenadas de cromaticidad y los promedios (en términos de valores L_, a_ y b_). El software desarrollado analiza adecuadamente el color de la piel de la fruta y también es capaz de clasificar la etapa de maduración de la guayaba como verde, madura, demasiado maduro y estropeado utilizando el análisis de componentes principales (PCA). En el diagrama de dispersión de PCA se observaron fácilmente los distintos grupos para las clases de madurez. También se usó una red neuronal artificial (ANN) para una mejor predicción de muestras desconocidas.

[24] presentan un método para calificar manzanas 'Jonagold'basadas en características extraídas de defectos. La base de datos que consta de imágenes multiespectrales y se utilizo el método de agrupación Fuzzy C-Means (FCM) para la segmentación de los defectos, las características de la parte defectuosa se extraen utilizando el método de Histograma de gradientes orientados (HOG) y la clasificación de manzanas se realiza mediante el uso de la Máquina de vectores de soporte multiclase (MSVM) con una precisión de 97.5 % para calificación de dos categorías (saludable y defectuosa) y 94.66% para calificación de múltiples categorías (manzanas saludables, manzanas con defectos leves y manzanas con defectos graves).

[11] desarrolla un enfoque de clasificación eficaz basado en el algoritmo de bosque aleatorio (RF). Tres frutas es decir, se analizaron las manzanas, las fresas y las naranjas y se extrajeron varias características según la forma de las frutas, las características del color y la Transformación de la Característica Invariante de la Escala (SIFT). Se presenta una etapa de preprocesamiento que utiliza el procesamiento de imágenes para preparar el conjunto de datos de imágenes de frutas para reducir su índice de color. Luego se extraen las características de la imagen del fruto. Finalmente, el proceso de clasificación de frutas se adopta utilizando bosques aleatorios (RF), que es un algoritmo de aprendizaje automático desarrollado recientemente. Se usó una cámara digital normal para adquirir las imágenes y todas las manipulaciones se realizaron en un entorno MATLAB. Los experimentos se probaron y evaluaron utilizando una

serie de experimentos con 178 imágenes de frutas. Muestra que el algoritmo basado en el bosque aleatorio (RF) proporciona una mejor precisión en comparación con las otras técnicas de aprendizaje automático bien conocidas, como los algoritmos de K-NN y de vector de soporte (SVM). Además, el sistema es capaz de reconocer automáticamente el nombre de la fruta con un alto grado de precisión.

[25] menciona que el color y el tamaño son una de las características más importantes para una clasificación precisa de madurez de las frutas. Los pequeños agricultores utilizan la evaluación manual a través de la observación visual para clasificar la madurez de su elección. que según FAMA hay seis índices de madurez. El proceso repetitivo es tedioso y es propenso al error humano. Este trabajo se centra en la identificación de la madurez de la fruta del mango. Raspberry Pi es una computadora pequeña, que es lo suficientemente potente como para ejecutar un algoritmo de procesamiento de imágenes que se elige para este sistema. El algoritmo de procesamiento de imágenes desarrollado puede determinar el tamaño de la fruta y aplicar el agrupamiento de K-means para determinar el color de la fruta.

[26] presenta un sensor de microondas que puede detectar frutas defectuosas. En este trabajo, el mangostán se utiliza como ejemplo. El translúcido se detecta al medir la frecuencia Doppler a medida que se hace girar el mangostán. Desde las ondas dispersas simuladas en diferentes direcciones alrededor de las frutas, las diferentes ondas dispersas dan como resultado una señal Doppler de la fruta defectuosa. La diferente tensión de CC de la mezcladora identificó si hay translúcida para toda la fruta. Este sensor rentable es un buen candidato para la clasificación de frutas.

[27] proponen el reconocimiento de imágenes visuales es uno de los componentes más importantes de los sistemas de control, sistemas de procesamiento de información y sistemas de toma de decisiones automatizados. En este documento se considera el enfoque para desarrollar un sistema de control de reconocimiento de objeciones basado en una red neuronal convolucional (CNN). La CNN se aplica a las tareas de detección y reconocimiento de frutas mediante la optimización de parámetros. El resultado de nuestra prueba tuvo una precisión en

la clasificación cercana al 94% para las 30 clases de 971 imágenes, lo que indica que el sistema y los métodos propuestos podrían usarse para aplicaciones de control basadas en subsistemas de visión.

[28] implementa un enfoque eficiente de la clasificación de la madurez de la fruta basada en el color aparente de la muestra con la ayuda del sistema de inferencia difusa (FIS). El matiz adquirido heurísticamente y su correspondiente saturación y luminosidad son los atributos de elección, que se utilizan para clasificar la muestra en tres clases; Crudo, maduro y demasiado maduro. Las funciones de membresía y las reglas difusas requeridas por el FIS de Mamdani se estiman por el enfoque del árbol de clasificación. La experimentación se realiza sobre 200 muestras de guayaba. El sistema difuso se entrena en el 60% del conjunto de datos, lo que arroja una precisión de clasificación del 93,4%.

1.2 Planteamiento del problema de investigación

¿Cual es el estado del conocimiento respecto a la clasificación automatizada no destructiva de frutas para determinar el estado de madurez?

1.3 Objetivos.

1.3.1 Objetivo general

Realizar una revisión del material bibliográfico sobre clasificación no destructiva de frutas utilizando visión artificial

1.3.2 Objetivos específicos

- Elaborar el plan de investigación
- Desarrollar el procedimiento de investigación
- Crear la documentación de la investigación

1.4 Marco teórico conceptual

Los fundamentos teóricos que soportan el proyecto son necesarios para entender el reconocimiento de ciertos patrones en diferentes tipos de datos siendo el procesamiento de imágenes el más utilizado el cual, captura utilizando visión artificial, lo que conlleva el uso de filtros, manipulación de las muestras, mejoramiento y transformación para su correcto análisis.

1.4.1 Fundamentos clasificación automatizada

El reconocimiento y la clasificación de frutas de acuerdo alguna característica es un tema que debe considerar muchas variables para ajustar los modelos y poder disminuir la curva de error. Cabe mencionar que, las frutas presentan características sensoriales y características cruciales que han sido el principio de las diferentes propuestas en materia de instigación. Se debe agregar que, existen desafíos importantes entorno a la clasificación de frutas los cuales se describen a continuación.

1.4.1.1 Dispositivos para la extracción de datos

El primer paso para realizar la clasificación objetiva de una fruta es la extracción de los datos y para ello se debe seleccionar un dispositivo (sensor) apropiado de acuerdo al objetivo a clasificar. Cabe mencionar que en los antecedentes previos se han utilizado dispositivos que van desde cámaras en blanco y negro (B/N) hasta sensores no visuales como los sensores acústicos y táctiles para la clasificación de frutas. Se debe agregar que, todos estos dispositivos no tienen el mismo resultado para toda las aplicaciones, como se evidencia en [29, 30, 9, 7], tanto los sensores acústicos como los táctiles son menos adecuados para la clasificación y el reconocimiento no destructivos ya que estos necesitan tener algún contacto directo físico con la fruta para la adquisición de los datos. Además, los sensores visuales son muy sensibles a muchos factores, por ejemplo, las condiciones de iluminación y el entorno de fondo. Estos factores básicos son una combinación de muchos factores complejos, incluyendo la reflexión, la refracción, la escala, la rotación y la traslación, que deben ser considerados en profundidad

para mejorar los resultados.

1.4.1.2 Características

Son la descripción física de un objeto para que este pueda ser diferenciado de otros objetos. Las frutas tienen varias características físicas, tales como color, textura, forma y tamaño, que se pueden utilizar como descriptores de una fruta para realizar la clasificación. Hay que mencionar, además que las frutas cuentan con muchas variaciones y similitudes entre y dentro de cada fruta lo que se conoce como similitud inter e intra clase. Se debe agregar que, las variaciones entre clases son cambios significativos, es decir, cambios en el color, la textura y la forma, mientras que las variaciones intraclase son generalmente mucho más sutiles y difíciles de diferenciar, es decir, que los diferentes tipos de mangos o manzanas, entre otras, sólo presentan ligeras variaciones en sus características [7, 31]. Todavía cabe señalar, que realizar la selección de las características de manera adecuada permitirá que un sistema automatizado pueda mejorar su rendimiento. Así mismo, la representación sistematizada de estas características es un factor muy importante para garantizar el éxito o fracaso de una prueba. Se debe agregar que, se han realizado propuestas con resultados muy significativos relacionadas con la clasificación de frutas haciendo uso de estas características para representar rasgos de la fruta, estas investigaciones exponen que el uso de una sola característica no puede considerarse suficiente para una clasificación eficaz de las frutas, o de los objetos en general ya que se deben considerar las demás características [1, 9, 11, 32], por ejemplo un fruto de mango no se podría clasificar solo por su color ya que garantizar la clasificación adecuada depende de diferentes características como el tamaño, la forma y el color, Además, de la variable luminosidad la cual es muy significativa en cuanto a la representación del color.

1.4.1.3 Modelo de color

[33] Son modelos matemáticos abstractos que permiten representar los colores en forma numérica,utilizando típicamente tres o cuatro valores o componentes cromáticas. Está basada en un conjunto de coordenadas, con base de N vectores, cuya conjunción lineal genera todo

el espacio de color. Así mismo, los modelos de color tratan de representar la mayoría de colores sensibles al ojo humano, aunque existen modelos que no tengan tal finalidad por no ser conveniente para su futura aplicación, Estos modelos se pueden clasificar de acuerdo al número de dimensiones empleadas como se evidencia en la (Tabla 1.1).

Dimensión	**Modelo de Color**
1 dimensión	Escala de grises
3 dimensión	RGB, HSI, HSV, CIE XYZ, CIE L*a*b*

Tabla 1.1: Clasificación de los modelos de color. **Fuente:** Elaboración propia

1.4.1.4 Entornos automatizados

Existen pruebas significativas de los esfuerzos realizados para la realización de un sistema automatizado de clasificación de frutas [34, 29], pero hasta la fecha no se dispone de ejemplos de aplicaciones comerciales de tales sistemas. Cabe mencionar que, la mayor parte de los esfuerzos planteados hoy en día tienen como idea central el uso de uno o más tipos de sensores junto con una técnica de aprendizaje automático para la identificación de las características asociadas con los productos, por ejemplo, la forma, el color, la textura y el tamaño para realizar la clasificación de las frutas.

1.4.2 Procesos para la clasificación automatizada

Las propuestas planteadas al día de hoy coinciden en que los esfuerzos realizados para realizar la clasificación de frutas sigue cierto proceso el cual se dividen en subprocesos específicos los cuales se muestran en la Figura1.1. Los cuales se describen a continuación según los aportes de los métodos expuestos en la Figura 1.1.

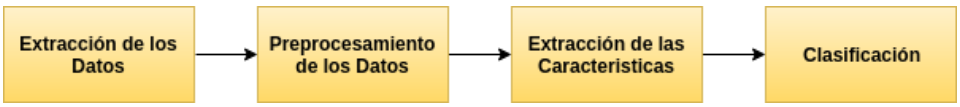

Figura 1.1: Procesos para la Clasificación Automatizada de Frutas. **Fuente:** Elaboración propia

1.4.2.1 Extracción de datos

La información que es utilizada como muestras para realizar la clasificación de una fruta consiste en un conjunto de datos predictores o representativos del mundo real los cuales se pueden recolectar bajo distintas técnicas digitales utilizando distintos dispositivos para la adquisición de dicha información. Cabe mencionar que existe que las propuestas planteadas exhiben un conjunto de sensores (activos, pasivos) para realizar dicha practica. Hay que mencionar, además que la elección del sensor depende de muchos factores a realizar en la propuesta por ejemplo si se va realizar un proyecto sumamente controlado o no controlado esto conllevara a tener en cuenta o no variables como reflectancia o iluminación.

1.4.3 Preprocesamiento de los datos

Los datos adquiridos utilizando los sensores apropiados [1.4.2.1], generalmente contienen algún tipo de ruido o distorsión en la información estos son denominados datos crudos en formato (RAW) los cuales no son adecuados para realizar algún tipo de extracción de características para realizar un sistema de visión por computador ya que de utilizar esta información el ruido o distorsión influiría de forma directa en la precisión, es por ello que es muy importante realizar el preprocesamiento de los datos para estandarizar la información; algunas de las técnicas mas utilizadas se describen a continuación.

1.4.3.1 Preprocesamiento

Los datos extraídos generalmente pertenecen al modelo de color RGB los cuales contienen mucha información redundante que necesita ser procesada estadísticamente para eliminar información que no es necesaria para la representación de una fruta y determinar la información

que falta debido al ruido, la distorsión y la sensibilidad variable de los sensores utilizados [11]. Las restricciones espaciales y no espaciales se aplican a la estimación de píxeles cuando cada método tiene sus ventajas, por ejemplo, la estimación no espacial se utiliza para mejorar el contraste. Además, la representación de objetos tridimensionales en imágenes bidimensionales provoca una distorsión geométrica que está sujeta a la posición relativa de la cámara y del objeto en el caso de imágenes fijas y a la velocidad, estabilidad y ángulo de la cámara para aplicaciones robóticas móviles [31]. Para solucionar estos inconvenientes se debe aplicar un preprocesamiento elemental significativo a los píxeles adyacentes para mejorar las diferencias entre ellos tales como suavizado de imagen y el gradiente utilizado para la detección de bordes.

1.4.3.2 Segmentación

Extraer la sección distintiva o descriptiva de una imagen se denomina región de interés (ROI) la cual se realiza utilizando la técnica de la segmentación [3]. Es necesario recalcar que, la segmentación de imágenes es un proceso fundamental para los sistemas de visión por computador que influye de forma directa en la efectividad general del análisis de imágenes. Existen muchas técnicas de segmentación basadas en el brillo, color, valores de escala de grises, textura y bordes que han sido exploradas en los antecedentes previos [1.1]. Sin embargo, a medida que las capacidades computacionales mejoran, las técnicas de segmentación más efectivas evolucionan.

1.4.4 Extracción de características

Teniendo la información estandarizada el siguiente paso es extraer un fragmento de la información relacionada con alguna propiedad particular de una fruta bajo alguna métrica necesaria para su representación, es decir que el reconocimiento, clasificación, recuperación y reconstrucción, se denomina descriptor de la característica. Las frutas tienen varias cualidades visuales distintas asociadas a ellas, llamadas características. Las características más comúnmente utilizadas para la clasificación y el reconocimiento de las frutas son el *color, la forma, el tamaño y la textura*. Un descriptor de características es global o parcial, dependi-

endo de su capacidad de representación. En particular para el reconocimiento de objetos, una característica global describe el objeto como un todo en forma de un descriptor generalizado, por ejemplo, la forma, y una característica local describe muchos puntos de interés en forma de parches de una imagen.

1.4.4.1 Descriptores de características de forma

La forma de las frutas se ha utilizado con frecuencia para la clasificación relacionado a la industria alimentaria. La forma y el tamaño (morfología) de las frutas desempeñan un papel fundamental en la estimación de los precios [5]. Esta característica también es importante para la clasificación automática en la industria alimentaria. Las formas esféricas o cuasiesféricas son más fáciles de describir como vectores de característica en comparación con las formas naturales y más complejas de frutas [10]. El vector de la característica de forma puede utilizarse para cuantificar la fruta y verdura, por ejemplo, estimando el tamaño por área de proyección, perímetro, longitud, anchura, diagonal mayor y menor para la estimación del tamaño en la industria alimentaria. Un descriptor de características de forma es un modelo matemático que intenta modelar la forma de un objeto en un método basado en la intuición humana, por ejemplo, la forma descrita como un conjunto de contornos. Una técnica preliminar de un descriptor de forma considera los puntos de interés importantes basados en el límite y el interior de las formas, varias categorías de puntos de interés de forma son características espectrales, curvaturas, contenido de forma, matriz de forma, momentos y firmas de forma.

1.4.4.2 Chain Code

Es una secuencia de vectores etiquetados por un conjunto de ocho símbolos para las ocho direcciones posibles de esta manera es posible representar objetos binarios conectados 8. Lo diferente los símbolos usualmente son dados por el alfabeto F8 = 0, 1, 2, 3, 4, 5, 6, 7 y están asignados al vecindario 8 en una contra sentido de las agujas del reloj [35]. La Figura 1.2 (a) muestra el código F8 que se puede usar para Representa el contorno o esqueleto utilizando celdas de resolución.

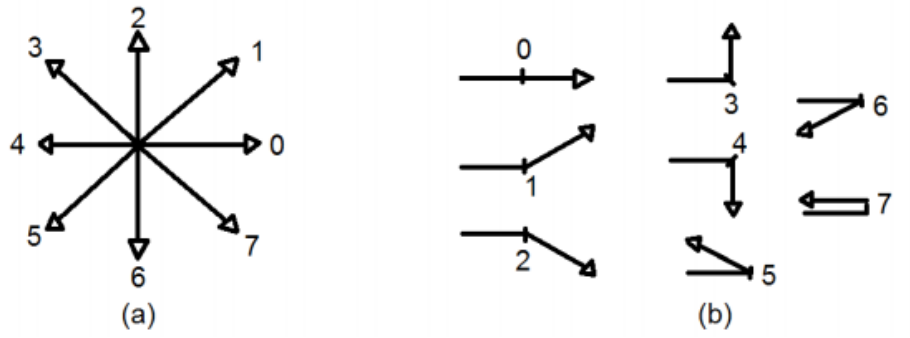

Figura 1.2: Los códigos utilizados: (a) Direcciones F8, (b) Direcciones relativas AF8 **Fuente:** [35]

1.4.4.3 Descriptores de la característica de textura

Las imágenes digitales siempre contienen alguna textura, ejemplos de los cuales van desde patrones espaciales en imágenes satelitales hasta la disposición de los tejidos en imágenes microscópicas. La textura es una de las propiedades más utilizadas de la fruta entre los colores y formas para su clasificación [32]. La textura es la disposición espacial de las primitivas llamadas texturas, que son estructuras fundamentales a nivel microscópico, es decir, los píxeles en las imágenes y los átomos en el sistema de percepción visual humano. La textura en las imágenes digitales sigue algunas propiedades estadísticas de la recursión periódica con algún grado de variación desde funciones estadísticas hasta funciones estocásticas. La textura como propiedad para la clasificación, reconocimiento, segmentación, síntesis y análisis de forma a partir de la textura ha sido ampliamente estudiada [36, 32, 2, 37, 38]

1.4.4.4 Descriptores de características de color

El color es la característica mas importante de selección o el rechazo de frutas para los clientes de un mercado o para el personal de evaluación de la calidad [39]. El color es la característica que se utiliza con más frecuencia para la recuperación y reconocimiento de imágenes, tiene ventajas significativas sobre otras características como la facilidad de extracción de alta frecuencia, invariable al tamaño, forma y orientación e independiente a la complicación del

fondo. Los colores se representan en diferentes espacios de color que están diseñados para un propósito específico [1.1]. Un espacio de color comúnmente conocido es el RGB, que representa la imagen en los planos rojo, verde y azul. Una imagen generada por los mismos píxeles en un espacio RGB puede tener diferentes valores RGB para diferentes dispositivos que necesitan ser transformados para su estandarización [1.4.1.1]. Esta naturaleza no lineal de RGB lo hace menos adecuado para la inspección visual humana. Para superar esta limitación de espacio RGB se han desarrollado otros espacios de color significativos, se ha desarrollado una descripción detallada de los diferentes espacios de color y su análisis comparativo se presenta en [40]. En general, la representación del color basada en el aprendizaje automático se utiliza para la clasificación de objetos a partir de imágenes o vídeos [36]. El color de una fruta se rige por cambios físicos, bioquímicos y microbianos durante la maduración y el crecimiento. Sin embargo, los cambios fotométricos, es decir, la orientación, la escala y la iluminación, pueden tener un efecto significativo en el color de la fruta como se evidencia en la Figura 1.3. Para reducir los efectos fotométricos, un descriptor de color debe tener una propiedad de invariabilidad significativa.

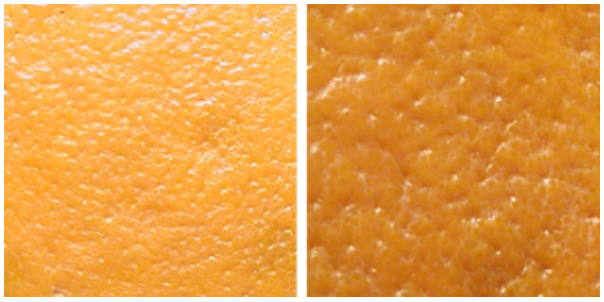

Figura 1.3: cambios en las imágenes digitales (reflectancia)

1.4.5 Clasificación

La clasificación de frutas es un tema ampliamente explorado teniendo al procesamiento de imágenes RGB como el proceso más estudiado para explotar características significativas de la

fruta, como el color, la forma, la textura y el tamaño de los sistemas convencionales de visión artificial. El análisis de calidad, la identificación de enfermedades y el análisis de daños se encuentran entre las principales aplicaciones de la clasificación de frutas basada en la visión artificial. Investigaciones recientes han utilizado una variedad de modelos de aprendizaje automático, por ejemplo, k-NN, SVM, árboles de decisión, Red Neuronal Artificial (RNA) y sus variantes para este propósito.

1.4.5.1 Algoritmos de clasificación

1.4.5.1.1 K Vecinos más próximos (k-NN)

Es un algoritmo de aprendizaje supervisado de clasificación, de modo que a partir de un juego de datos de entrenamiento su objetivo será clasificar correctamente todas las instancias nuevas. El juego de datos típico de este tipo de algoritmos está formado por varios atributos descriptivos y un solo atributo objetivo, también llamado clase GironesRoigJordi2017.

Entrada: k (número de vecinos) y x (nueva instancia a clasificar)
    para todo $d_i \in D$ **hacer**
        Calcular la distancia $d(d_i; x)$
    fin para
    Inicializar I con las clases ci de las k instancias de entrenamiento más próximas a x.
    devolver La clase mayoritaria en I

Tabla 1.2: Pseudocódigo del algoritmo k-NN. Fuente: [6]

1.4.5.1.2 Árbol de decisión

Es uno de los modelos de minería de datos más comunes y estudiados, y no precisamente por su capacidad predictiva, superada generalmente por otros modelos más complejos, sino por su alta capacidad explicativa y la facilidad para interpretar el modelo generado [6]. Básicamente, los árboles de decisión son un modelo de minería de datos que intenta subdividir el espacio de datos de entrada para generar regiones disjuntas, de forma que todos los elementos que pertenezcan

a una misma región sean de la misma clase, la cual es utilizada como representante o clase de dicha región. Así, un árbol de decisión se llama completo o puro si es posible generar una partición del espacio donde cada subregión solo contenga elementos de una misma clase.

```
Entrada: conjunto de datos a clasificar D
    T = D // El árbol inicial es un solo nodo hoja
    Etiquetar T de acuerdo a C_c
    p = T // Lista de nodos pendientes (hojas)
    mientras no se deba parar según C_p hacer
        Seleccionar un nodo q de acuerdo a C_s
        si es posible particionar q según C_d entonces
            Particionar q en q_1, ..., q_P
            Etiquetar q_1, ..., q_P según C_C
            Añadir q_1, ..., q_P a p
            Sustituir q en T por un nodo interno
        fin si
        Eliminar q de p
    fin mientras
    devolver T
```

Tabla 1.3: Pseudocódigo del algoritmo árbol de decisión. Fuente: [6]

1.4.5.1.3 Random Forests (RF)

Es uno de los mejores métodos de clasificación y regresión para el aprendizaje automático. Es adecuado para la clasificación de un gran número de conjuntos de datos. Se trata de tener un grupo de clasificadores estructurados por árboles. El árbol depende de los valores aleatorios muestreados y del bosque. La entrada se da en la parte superior del árbol y luego hacia abajo. Los datos que se muestrean son aleatorios, pero están teniendo conjuntos reducidos. La clase de muestra se encuentra en los árboles de bosques aleatorios, que son de un número aleatorio. La variable aleatoria encontró cómo se encuentran los cortes regularmente. En el momento de la construcción del árbol seleccionando el nodo y la coordenada a dividir y la posición del dividido [37].

1.4.5.1.4 Maquinas de vectores de soporte (SVM)

En el aprendizaje automático, las máquinas vectoriales de apoyo son sistemas de aprendizaje supervisado basados en la teoría del aprendizaje estadístico para la clasificación de datos y el reconocimiento de patrones en problemas de clasificación y análisis de regresión [6]. Este método se utiliza para la clasificación de datos lineales y no lineales. En el modelo de máquina vectorial de apoyo, las muestras se presentan como puntos en el espacio y se cartografían de tal manera que las muestras de las distintas clases están separadas por un límite claro que es lo más amplio posible. En este método, un límite óptimo de dos conjuntos de datos en un espacio vectorial se conoce como un hiperplano, que se obtiene independientemente de la distribución probabilística de los vectores de entrenamiento en el conjunto. Originalmente, el SVM se introdujo para los problemas relacionados con dos clases solamente, pero podemos extenderlo para problemas multiclase usando cerca de una parcela contra una clase o una contra todas las estrategias. Si el espacio entre dos conjuntos de datos no es separable linealmente, es decir, no hay un hiperplano separador para distinguir las clases, se puede utilizar una función del núcleo. La función kernel evalúa las relaciones dentro de los datos y realiza divisiones complejas en el espacio [24]. El SVM tiene la tasa de precisión más alta en comparación con otras técnicas.

1.4.5.1.5 Redes neuronales artificiales (RNA)

Es un sistema de procesamiento de información distribuido masivamente paralelo, compuesto por neuronas artificiales, con ciertas características de rendimiento que se asemejan a las neuronas biológicas del cerebro humano[6]. Una red neuronal se caracteriza por su arquitectura que representa en qué patrón está conectada entre nodos y qué método se utiliza para determinar los pesos de conexión y la función de activación. La arquitectura jerárquica de feed forward es la RNA más utilizada [37].

1.4.5.1.6 Fuzzy logic

Zadeh propuso la teoría de los conjuntos difusos. Esta teoría introdujo la realización de las operaciones de la función de membresía sobre el rango de números reales [0, 1]. Para calcular

las funciones lógicas de membresía, se propusieron nuevas operaciones que demostraron ser una herramienta razonable para generalizar la lógica clásica. La lógica difusa es un procedimiento de clasificación no paramétrica que puede deducir la clasificación no lineal entre entrada y salida, y mantener la flexibilidad en la toma de decisiones incluso en problemas complejos. Los sistemas difusos proporcionan los medios para traducir el conocimiento experto de los humanos sobre el proceso en términos de reglas difusas (IF-THEN). Una regla difusa es la unidad básica para adquirir conocimientos sobre sistemas difusos. Al igual que una regla convencional en la inteligencia artificial, el sistema difuso tiene dos componentes: una parte "si" y una parte "entonces" que también se conocen como antecedentes y consecuentes, respectivamente [37]. Fuzzy es fácil de entrenar y requiere menos muestras. Sin embargo, ofrece una tasa de precisión más baja en comparación con cualquier otro clasificador.

2. MÉTODO DE INVESTIGACIÓN

El procedimiento de revisión del material bibliográfico del presente proyecto es una adaptación del método planteado por [41]. El cual tiene como objetivo proveer un marco para llevar a cabo el desarrollo de la revisión bibliográfica de un tema específico de forma concisa, válida y justificable. Teniendo en cuenta lo antes mencionado, se desarrolla el proyecto centrándose en la clasificación de frutas de acuerdo a ciertas características utilizando inteligencia artificial para automatizar el procedimiento. Se debe agregar que se ha optado por estudiar un rango de 9 años entre el 2010 y 2018. A continuación se realiza una descripción del método mencionado en la Figura 2.1.

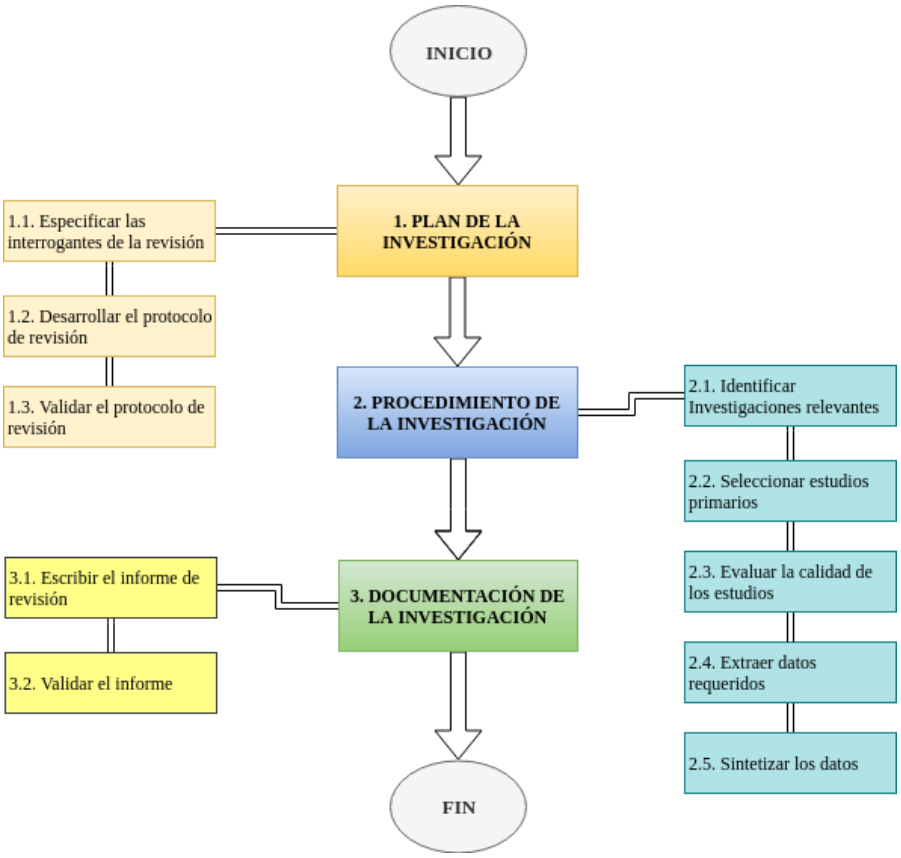

Figura 2.1: Método de revisión bibliográfica **Fuente:** Elaboración propia basado en [41]

2.1 Plan de la investigación

Tiene como objetivo describir la planificación a llevar a cabo para realizar el procedimiento de revisión bibliográfica especificando a detalle los pasos a seguir para garantizar una consistencia de información a tratar. Este plan describe en los tres pasos siguientes.

- Interrogantes de investigación que el estudio responderá
- Proceso que se seguirá para la búsqueda de la información
- Condición que se aplique al seleccionar los artículos a incluir en la búsqueda de la información.

2.1.1 Interrogantes de la investigación

Las interrogantes que se plantea responder el estudio se describen a continuación.

PRE 1. ¿Cuánto material bibliográfico relacionado a la clasificación de frutas utilizando visión artificial se ha publicado entre el año 2010 y 2018?

PRE 2. ¿Cuál es el la técnica predominante para realizar el procedimiento de clasificación de frutas?

PRE 3. ¿Dónde se centran los principales problemas en cuanto estado actual del proceso de clasificación de frutas?

PRE 4. ¿En que convergen las conclusiones relacionadas a la clasificación de frutas?

2.1.2 Protocolo de revisión

El protocolo de investigación define un conjunto de reglas en las cuales se detalla el proceso de revisión de la información relacionada a la clasificación de frutas de modo de especificar el cómo se extrajo la información y por qué. Se debe agregar que para este proyecto el primer paso es clasificar las bases de datos en las cuales se realizan la búsqueda de los artículos

relacionados, para ello se hace uso de la plataforma SCImago Journal & Country Rank[1] la cual incluye revistas y sus indicadores científicos a partir de la información contenida en la base de datos Scopus[2]. Estos indicadores se utilizan para evaluar y analizar las publicaciones científicas. Se ha tomado las primeras 2 bases de datos más relevantes según el filtro SCImago[3] al 2017, como se especifica en Figura 2.2.

Si bien es cierto cada conjunto de datos tiene su propia configuración de búsqueda esta sigue patrones similares, pero esto no impide crear reglas y criterios de búsqueda para cada una de ellas. Lo dicho hasta aquí supone que se recuperó investigaciones relacionadas a las interrogantes planteadas [2.1.1], también se tiene en cuenta que el proceso de clasificación de frutas es considerado uno de los más importantes para garantizar la calidad del producto existe un amplio material bibliográfico, se debe aclarar que este proyecto solo considera artículos publicados en revistas según la base de datos antes mencionada. Además, para garantizar la revisión del material más reciente se tiene en cuenta el rango entre el 2010 y 2018. Por otra parte, se diseña la regla de búsqueda que se ajuste al objetivo real de la investigación según las especificaciones de las bases de datos las cuales producirán los mejores resultados efectivos y completos, luego se opta por elegir las propuestas que mejor se ajusten.

[1] SCImago: `https://www.scimagojr.com/`
[2] Scopus: `https://www.scopus.com/home.uri`
[3] Filtro SCImago: [ciencia de la computación, Inteligencia artificial, todos los países, todos los tipos, 2017]

	Título	Tipo	SJR	↓ Índice h	Docs totales. (2017)	Docs totales. (3 años)	Total Refs.	Cites totales (3 años)	Cita Docs. (3 años)	Cita / doc. (2 años)	Árbitro. / Doc.
1	Transacciones IEEE sobre análisis de patrones e inteligencia de máquinas	diario	2.367 Q1	305	323	583	9478	7351	575	11.38	29.34
2	Transacciones IEEE en redes neuronales y sistemas de aprendizaje	diario	3.406 Q1	169	507	703	11108	6271	693	8.54	21.91
3	Reconocimiento de patrones	diario	1.065 Q1	168	426	967	19983	4734	949	4.62	46.91
4	Revista Internacional de Visión por Computador	diario	2.301 Q1	165	111	269	5633	3263	249	13.74	50.75
5	Transacciones IEEE en sistemas difusos	diario	4.024 Q1	163	259	454	5986	4348	452	8.59	23.11

Figura 2.2: Resultado del filtro de la plataforma SCImago Journal & Country Rank **Fuente:** Elaboración propia

2.1.3 Validar Protocolo de revisión

Se ha validado el protocolo de revisión. Las búsquedas iniciales condujeron a revisiones del protocolo y las preguntas de investigación. Además, la validación será discutida más tarde utilizando un contenido proceso de análisis de las palabras clave de los incluidos en los artículos.

2.2 Procedimiento de la investigación

2.2.1 Identificar las investigaciones relevantes

En este punto se buscan las propuesta más relevantes que proporcionan la mayor información con el fin de responder las interrogantes planteadas[2.1.1]. Cabe mencionar que, la propuesta de revisión se centra estrictamente en la clasificación automatizada no destructiva de frutas es por ello que se ha diseñado una regla genérica de búsqueda utilizando *"and"* booleano para unir los principales términos *"fruta, clasificación, algoritmos supervisados y color"* como se muestra en la Tabla 2.1. Además, se ha revisado la base de datos IEEE, finalmente se determinó que revistas serán la fuente principal de esta revisión bibliográfica para garantizar la calidad de este estudio en la Figura 2.3 la cual expone el resultado crudo del

filtro.

Nº	Base de datos	Regla de búsqueda	Resultados
1	IEEE Transactions on Pattern Analysis and Machine Intelligence	(‘fruit AND classification AND supervised algorithms AND color’)	51
2	IEEE Transactions on Neural Networks and Learning Systems		

Tabla 2.1: BÚSQUEDA DE BASE DE DATOS Y RESULTADOS. **Fuente:** Elaboración propia

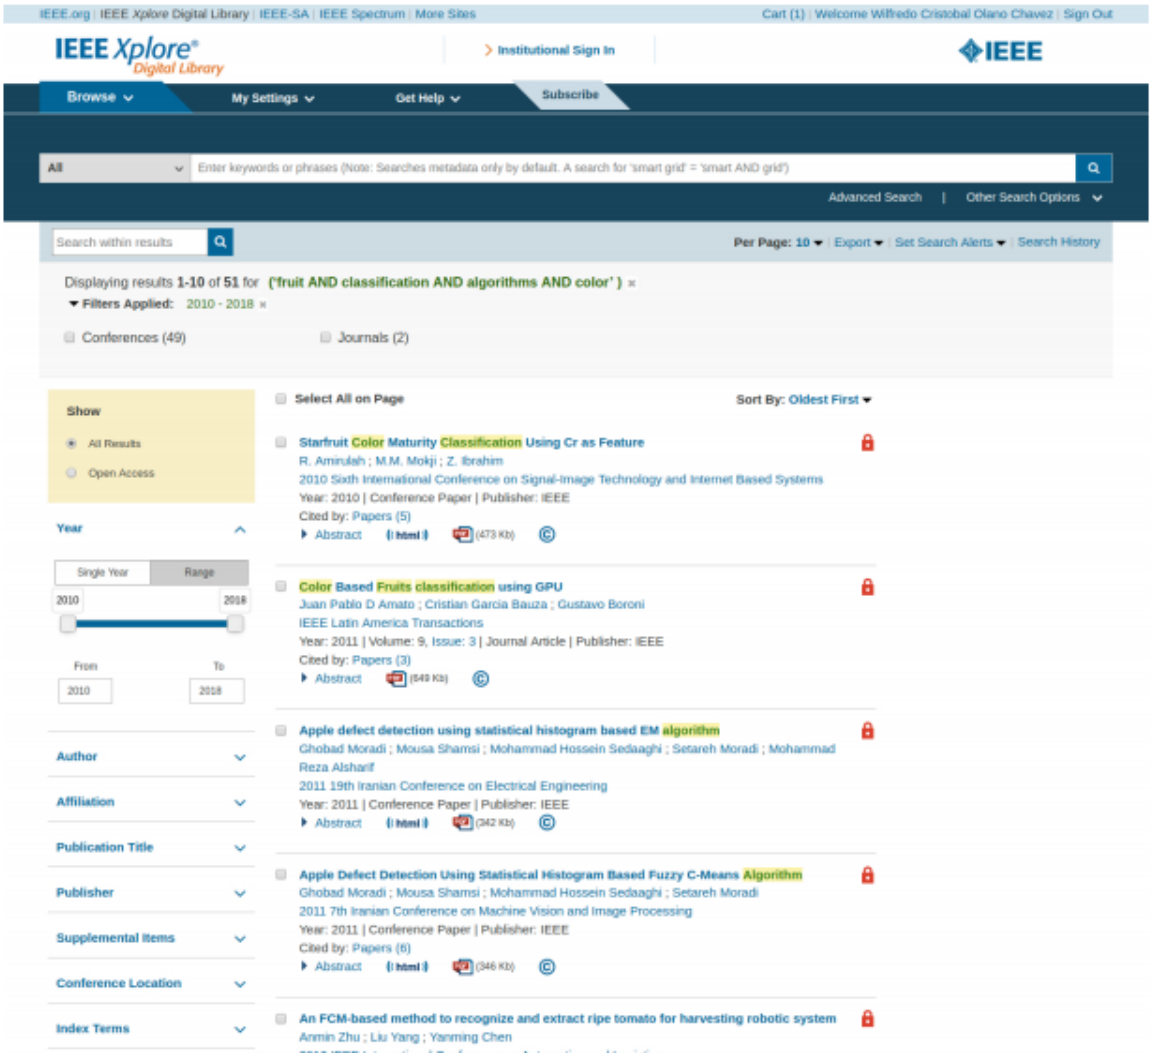

Figura 2.3: Resultado crudo de la búsqueda IEEE. **Fuente:** IEEE Xplore Digital Library

2.2.2 Seleccionar los estudios primarios

La selección de los estudios incluidos en el proyecto se lleva a cabo gracias a los distintos indicadores (palabras clave, revistas, resumen, cantidad de referencias, número de citas) comparadas a partir del resultado de aplicar la búsqueda utilizando la regla planteada anteriormente, para tomar los estudios que describan de forma más ecuánime posible el objetivo de la revisión. A continuación, se describe las tendencias de los estudios filtrados haciendo énfasis en el año de la publicación, tipo de fruta, característica, eficiencia, porcentaje de precisión que se obtuvo en las propuestas planteadas y las referencias a estas.

Nº	**Año**	**Fruta**	**Característica**	**Eficiencia**	**Ref.**
1	2010	Carambola	Color	96%	[1]
2	2011	Manzana	Color	83.3%	[34]
3	2011	Manzana	Color (algoritmo EM)	91.72%	[3]
4	2011	Manzana	Color (algoritmo C-Means)	96%	[8]
5	2012	Tomate	Morfología, Color, Forma	-	[29]
6	2012	Manzana	Color	100%	[4]
7	2012	Mango	Color	90.91%	[5]
8	2012	Naranjas, Mandarinas, manzanas, limones y tomates	Color	88%	[9]
9	2013	Grosella	Color y textura	90%	[7]
10	2013	Almendras	Color	88%	[31]
11	2013	Uva y manzana	Color, textura y morfología	90%	[10]
12	2014	Cítricos	-	-	[42]
13	2014	Palta	Color, forma	82,22%	[43]
14	2014	Tomate	Color, textura	98%	[32]
15	2014	Frutas	Color	-	[44]
16	2014	Manzana, Fresa y Naranja	Color, textura	92.31%	[11]
17	2014	Cítricos	Textura	-	[36]
18	2015	Productos agrícolas	Color	-	[45]
19	2015	Aceituna	Color	100%	[46]
20	2015	Tomate	Color, textura y forma	-	[47]
21	2015	Frutas	Color, textura y forma	-	[37]
22	2015	-	Color, textura y forma	-	[48]
23	2015	Manzana	Color	-	[49]
24	2015	Mango	Color	90.4%, 84.2%	[50]
25	2015	Granada	Color	90%	[51]
26	2016	Manzana	textura	80%,82%	[52]
27	2016	Cacao	Color	89.2%	[53]

28	2016	Mango	Color y textura	90.09%, 90.26%,90.26%	[38]
29	2016	Manzana	Color y textura	97.5%, 94.66%	[24]
30	2017	Banano	Color	93.11%	[54]
31	2017	Manzana	Color	98.1%	[55]
32	2017	Frutas	Color y textura	96%	[56]
33	2017	Manzana	Color y textura	-	[57]
34	2017	Frutas	Forma y color	92.5%,90%	[58]
35	2017	Mango	Forma y color	-	[25]
36	2017	Frutas	Forma y color	90%	[59]
37	2018	Naranja	Color y forma	93.13%, 93.45% y 93.24%	[60]
38	2018	Manzana	Color	85%	[61]
39	2018	Durian	Forma, color	100%	[62]
40	2018	Café	Color	81.81%	[63]
41	2018	Manzana	Color	91%	[64]
42	2018	Naranja	Color	91%	[65]
43	2018	Mango	Color, textura y forma	-	[66]
44	2018	Frutas	Color, textura y forma	93%-99%	[67]
45	2018	Canarium Ovatum (Pili)	Color	90.77%	[68]
46	2018	Frutas	Color	-	[69]
47	2018	Frutas	Color	-	[70]
48	2018	Manzana	Color	96-97%	[71]
49	2018	Frutas	Borde	-	[72]
50	2018	Frutas	Color	-	[73]
51	2010	Limón	Color y tamaño	94.04%	[12]
52	2010	Fresa	Forma y color	90%	[13]
53	2012	Manzana	Forma y color	90%, 88.8%	[17]
54	2011	Manzanas, plátanos, zanahorias, mangos y naranjas	Forma y color	79-90%	[14]
55	2012	Manzana, chikoo, naranja, mango y limón dulce	Color y textura	94%, 93%, 93%, 92% y 92%	[15]
56	2012	Mozafati	Color	86%	[16]
57	2012	Manzana	Color	100%	[17]
58	2012	Mango	Color y textura	80%	[18]
59	2012	Manzana	Color	95.24%	[19]
60	2013	Naranja	Forma, intensidad y textura.	100%, 92% y 96%	[20]

Tabla 2.2: RESUMEN DE LAS PROPUESTAS PLANTEADAS DESDE EL 2010 - 2018.
Fuente: Elaboración propia

2.2.3 Evaluar la calidad de los estudios

En este paso, la calidad de la investigación se abordó con el criterio de inclusión de la revisión integradora. La inclusión criterios para esta revisión integral de la literatura incluyó artículos de revistas que realizaron investigaciones relacionadas a la clasificación de frutas *(Regla: ('fruit AND classification'))*. Además de la evaluación del enfoque de investigación del documento, se evaluó el impacto global y el valor del H-index de las revistas. El valor de impacto es "el número de citaciones ponderadas en el año seleccionado por el documentos publicados en la revista seleccionada en tres años anteriores"[74]. El H-index "cuantifica tanto la productividad científica de la revista como la productividad científica impacto"[74]. En la Tabla 2.3 se muestra la SCImago Journal Rank[1] (impacto #) y el H-index de cada documento incluido en este estudio. Cabe mencionar que, la mayoría de los documentos incluidos en este estudio fueron publicado en revistas de impacto en las que el valor medio de impacto es de 0.64 y la media de El H-index es 67.4.

Articulo	**Revista**	**Impact #**	**H-Index**
1	IEEE Sensors Journal	0.73	100
2	IEEE Access	0.61	56
3	IEEE Transactions on Instrumentation and Measurement	0.88	100
4	IEEE Robotics and Automation Letters	0	0
5	IET Systems Biology	0.42	43
6	IEEE Transactions on Instrumentation and Measurement	0.88	100
7	IEEE Sensors Journal	0.73	100
8	Neural Computation	0.89	148
9	IEEE Sensors Journal	0.73	100
10	IEEE Access	0.61	56
11	IEEE Access	0.61	56
12	IEEE Transactions on NanoBioscience	0.54	55
13	IEEE Access	0.61	56
14	IEEE Access	0.61	56
15	IEEE Access	0.61	56
16	IEEE Transactions on Instrumentation and Measurement	0.88	100
17	IEEE Transactions on Industrial Informatics	1.68	100
18	IEEE Sensors Journal	0.73	100
19	IEEE Latin America Transactions	0.34	19
20	IEEE Sensors Journal	0.73	100
21	IEEE Latin America Transactions	0.34	19

22	IEEE Access	0.61	56
23	IET Image Processing	0.35	34
24	IEEE Access	0.61	56
25	IEEE Latin America Transactions	0.34	19
#	**Promedios**	**0.64**	**67.4**

Tabla 2.3: RESUMEN DE IMPACTO DE LAS REVISTAS (2010-2018). **Fuente:** Elaboración propia

2.2.4 Extraer datos requeridos

Para responder a las preguntas de investigación, se extrajeron los siguientes datos de cada estudio:

1. Las palabras clave que se utilizarán en un análisis de contenido para determinar en última instancia las categorías de investigación en comunicación (la taxonomía)

2. Tipo de datos recogidos: cualitativos, cuantitativo, encuesta, revisión de la literatura

3. Suficiente información para determinar el resultado principal

4. La información de la revista para permitirnos determinar su valor de impacto y el valor del H-index

2.2.5 Sintetizar los datos

Los resultados de la síntesis de datos se utilizan para determinar los temas principales dentro de la investigación relacionada a la clasificación automatizada de frutas y para categorizar cada artículo seleccionado y así poder determinar las categorías de investigación. Se realizó un análisis del contenido de las palabras clave de cada artículo haciendo énfasis en el significado de cada palabra o concepto el cual va más allá de simplemente contar palabras para examinarlas. Se debe aclarar que para realizar este análisis se basa en la la valoración de los términos controlados por INSPEC[4] la cual es una importante base de datos de indexación de literatura científica y técnica, publicada por el Instituto de Ingeniería y Tecnología. El resultado de esta

[4]INSPEC `https://www.theiet.org/publishing/inspec/`

evaluación se muestra Tabla 2.4, la cual expone el título de la publicación, autor, año de la publicación, palabras clave del autor, términos controlados por IEEE, términos controlados y no controlados por INSPEC número de citas y referencias de cada publicación. Además, en la Figura 2.4 se muestra una comparación entre el número de citas y la cantidad de veces que ha sido referenciado cada artículo revisado.

Tabla 2.4: VALORACIÓN DE LAS PALABRAS CLAVE DE ACUERDO A INSPEC

Nº	Título del documento	Autores	Año	Palabras clave del autor	Términos de IEEE	Términos controlados por INSPEC	Términos no controlados de INSPEC	# de citas	# de Ref.
1	Clasificación de madurez de color de Starfruit usando Cr como característica	R. Amirulah; MM Mokji; Z. Ibrahim	2010	Madurez del color de Starfruit; en tiempo real; adquicisión de la imagen; espacio de color YCbCr; clasificación	Análisis de color de la imagen; algoritmos de clasificación; modelo matemático; índices; ecuaciones; formación; extracción de características	Productos agrícolas; agricultura; extracción de características; clasificación de imágenes; análisis de color de imágenes; inspección; control de calidad; sistemas en tiempo real	Clasificación de madurez del color de Starfruit; inspección de calidad; sistema en tiempo real; dispositivo de adquisición de imágenes; cámara CCD; espacio de color RGB; espacio de color YCbCr; extracción de características	5	15
2	Clasificación de frutas basadas en color utilizando GPU	JP D Amato; C. García Bauza; G. Boroni	2011	Agricultura; Análisis del color de la imagen; Detección de objetos; Procesamiento paralelo	Java; Comunicación móvil; Bases de datos; Sol; Comunicación inalámbrica; Servidores; Asistentes digitales personales	-	-	3	0
3	Detección de defectos de Apple utilizando algoritmo EM basado en histograma estadístico	G. Moradi; M. Shamsi; MH Sedaaghi; S. Moradi; MR Alsharif	2011	Segmentación de imágenes; defectos de manzana; espacio de color; histograma estadístico; algoritmo de maximización de expectativas; modelo de contador activo	Análisis de color de imágenes; Segmentación de imágenes; Píxeles; Histogramas; Precisión; Algoritmos de clasificación	Análisis de color de imágenes, segmentación de imágenes, métodos iterativos, análisis estadístico.	Detección de defectos de manzana; histograma estadístico; algoritmo EM; segmentación de imágenes; aplicación de procesamiento de imágenes; algoritmo automático; defectos de color de piel de manzanas; RGB; algoritmo ACM; algoritmo SHEM; iteración; píxeles sanos	0	21

4	Detección de defectos de Apple mediante el uso de histograma estadístico basado en un algoritmo difuso de medios C	G. Moradi; M. Shamsi; MH Sedaaghi; S. Moradi	2011	-	Análisis del color de la imagen; Segmentación de la imagen; Algoritmos de agrupamiento; Algoritmos de clasificación; Histogramas; Color	Visión por computadora; extracción de características; productos alimenticios; análisis de color de imagen; segmentación de imagen; detección de objetos; computación de ingeniería de producción; control de calidad; análisis estadístico	Detección de defectos de manzana; histograma estadístico basado en algoritmos difusos de c-medias; segmentación de imágenes; procesamiento de imágenes; visión por computadora; partición de imágenes; determinación de la calidad de manzanas; defectos de color de piel de manzana; espacios de color; rojo-verde-azul; extracción de forma de fruta; algoritmo ACM; Algoritmo SHFCM	6	18
5	Un método basado en FCM para reconocer y extraer tomate maduro para el sistema robótico de cosecha	A. Zhu; L. Yang; Y. Chen	2012	Espacio de color; agrupación de FCM; morfología matemática; extracción de objetos	Análisis del color de la imagen; Segmentación de la imagen; Algoritmos de agrupamiento; Reconocimiento de la imagen; Morfología; Color; Forma	Productos agrícolas; control de ingeniería informática; extracción de características; teoría de conjuntos difusos; invernaderos; análisis de color de imágenes; reconocimiento de imágenes; segmentación de imágenes; sensores de imágenes; clasificación de patrones; visión de robot	Método basado en FCM; reconocimiento de tomate maduro; extracción de tomate maduro; sistema robótico de recolección; proceso de visión; fondo incierto; medios C difusos; efecto invernadero; imagen en color; sensor de visión; espacio de color CIE L * a * b *; componente de la característica de color; característica geométrica	0	11
6	Clasificador Multi Class Support Vector Machines para aplicación de visión artificial.	J. Suriya Prakash; K. Annamalai Vignesh; C. Ashok; R. Adithyan	2012	Máquinas de vectores de soporte (SVM); Núcleo de función de base radial (RBF); Visión artificial	Máquinas de vectores de soporte; Kernel; Capacitación; Visión artificial; Exactitud; Algoritmos de clasificación; Análisis de color de imagen	Inspección óptica automática; extracción de características; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; reconocimiento de objetos; computación de ingeniería de producción; redes de funciones de base radial; máquinas de vectores de soporte	Clasificador de máquina de vectores de soporte multiclase; aplicación de visión artificial; clasificación de objetos; máquinas de vector de soporte; algoritmo de clasificación de datos; rendimiento de generalización de datos; clasificador SVM multiclase; método de votación de uno-uno-máximo de ganancias máximas; función de base radial; núcleos lineales; color de fruta de manzana basada en la clasificación; k-clasificadores vecinos más cercanos; KNN Bayes clasificadores; Naive Bayes clasificadores; Kernel RBF	3	8

7	Clasificación de mangos por características de objeto y modelado de contorno.	S. Mohamed Mansoor Roomi; R. Jyothi Priya; S. Bhumesh; P. monisha	2012	Modelado de contorno de objetos; descriptor de Fourier; clasificador de Bayes	Extracción de características; Segmentación de imágenes; Forma; Análisis de color de imágenes; Polinomios; Algoritmos de clasificación; Industrias	Métodos de Bayes; visión por computadora; cultivos; extracción de características; clasificación de imágenes	Madurez del color de Starfruit; en tiempo real; acqiusition de la imagen; espacio de color YCbCr; clasificación	1	12
8	Clasificación de objetos sólidos con formas definidas utilizando visión estereoscópica y un brazo robótico	F. Medina; B. Nono; H. Banda; A. Rosales	2012	-	Resúmenes; Procesamiento de imagen estéreo; Forma; Análisis de color de imagen; Algoritmos de clasificación; Reconstrucción de imagen	Adquisición de datos; manipuladores hábiles; clasificación de imágenes; análisis de color de imágenes; reconstrucción de imágenes; textura de imágenes; aprendizaje (inteligencia artificial); escenas naturales; redes neuronales; detección de objetos; visión de robots; procesamiento de imágenes estéreo	identificación del tomate; posicionamiento del brazo robótico; reconstrucción de la escena; verificación del funcionamiento del sistema; identificación de la mandarina; identificación de la naranja; identificación de la manzana; identificación del limón; características del color; entrenamiento de la red neuronal artificial; problema de visión estereoscópica; Matlab; control del brazo robótico; adquisición de imágenes; LabVIEW; computacional algoritmos; características del color del objeto; forma del objeto; manipulación de objetos; clasificación de objetos; coordenadas XYZ; estimación de profundidad; módulo didáctico; clasificación de objetos sólidos	10	0

9	Técnica de evaluación de calidad no destructiva para Phyllanthus Emblica (Gooseberry) procesada que utiliza procesamiento de imágenes	RK Patel; KR Jain; TR Patel	2013	Procesamiento de imágenes; procesado phyllanthus emblica (grosella); Colorización con swtches y optimización; Función de textura; Método no destructivo; Detección de bordes en cualquier punto; Medición combinada	Histogramas; Detección de borde de imagen; Análisis de color de imagen; Forma; Detectores; Extracción de características; Algoritmos de clasificación	productos agrícolas; inspección óptica automática; análisis de color de imagen; textura de imagen; comercio internacional; pruebas no destructivas; computación de ingeniería de producción; control de calidad	Técnica de evaluación de la calidad no destructiva; phyllanthus emblica procesada; procesamiento de imágenes; color; característica de la textura; Rusia; productores de grosella; Asia del Norte; Alemania; Polonia; Reino Unido; India; evaluación de la calidad de la fruta; mercado internacional; industria de exportación de grosella, coloración	1	15
10	Segmentación de la fruta del huerto utilizando el aprendizaje multispectral.	C. Hung; J. Nieto; Z. Taylor;J. Underwood; S. Sukkarieh	2013	-	Segmentación de imágenes; Extracción de características; Análisis de color de imágenes; Capacitación; Precisión; Robots; Forma	productos agrícolas; clasificación de imágenes; segmentación de imágenes; aprendizaje (inteligencia artificial); robots móviles; visión de robots	Segmentación de la fruta del huerto; precisión de clasificación global; datos multiespectrales; granja de almendras; varianza de la fruta; estimación del rendimiento; misión de vigilancia agrícola robótica; problema de la segmentación de la fruta; árboles de dosel; características basadas en aplicaciones hechas a mano; escenarios de agricultura; métodos de clasificación; datos de imagen multiespectrales; condicional campo aleatorio; automatización de la segmentación de frutas; enfoque de segmentación de imágenes multiclase; aprendizaje multiespectral de características	30	24

11	Procesamiento de imágenes para agricultura inteligente: detección de enfermedades y clasificación de frutas.	M. Jhuria; A. Kumar; R. Borse	2013	Color; morfología; textura; segmentación; paquete de wavelet; red neuronal artificial; propagación hacia atrás	Enfermedades; Análisis de color de la imagen; Bases de datos; Extracción de características; Morfología; Redes neuronales artificiales; Vectores	Productos agrícolas; backpropagation; biología informática; agricultura; clasificación de imágenes; análisis de color de imágenes; recuperación de imágenes; textura de imágenes; redes neuronales; detección de objetos; enfermedades de plantas; bases de datos visuales	Procesamiento de imágenes; agricultura inteligente; detección de enfermedades; clasificación de frutas; industria agrícola; planta; concepto de red neuronal artificial; enfermedades de la uva; bases de datos de imágenes; consulta de imágenes; base de datos de capacitación; ajuste de peso; concepto de propagación hacia atrás; clasificación de imágenes; morfología de vectores de características; textura de imagen; análisis de color de la imagen; conteo de mango; Matlab; enfermedades de la manzana; mapeo de imágenes	31	9
12	Sistema de clasificación de cítricos en tiempo real basado en FPGA	MA Nuño-Maganda; Y. Hernández-Mier; C. Torres-Huitzil; J. Jiménez-Arteaga	2014	-	Análisis del color de la imagen; Arquitectura de la computadora; Hardware; Arreglos de puertas programables en campo; Itrio; Visión por computadora; Ecuaciones	Productos agrícolas; visión por ordenador; arrays de puertas programables en campo; clasificación de imágenes; análisis de color de imágenes; inspección; ingeniería de producción informática	utilización de recursos de hardware; Spartan-6 FPGA; imágenes en color; arquitectura de hardware; arreglo de puertas programables en el campo; sistema de selección de cítricos basado en color integrado; operadores de visión por ordenador; máquina de clasificación automática; algoritmos de visión por ordenador; inspección manual; inspección visual; clasificación de frutas; México ; industria de cítricos; sistema de clasificación de cítricos en tiempo real	0	11
13	Sistema automatizado para clasificar los aguacates Hass según las técnicas de procesamiento de imágenes.	Edgar Roa Guerrero;Gustavo Meneses Benavides	2014	Aguacates Hass, procesamiento de imágenes, clasificación automática.	Análisis del color de la imagen; Comunicación inalámbrica; Algoritmos de clasificación; Filtros Wiener; Diseño y análisis de algoritmos; Exactitud	Productos agrícolas, agricultura, clasificación de imágenes.	Sistema automatizado de clasificación de aguacates Hass; agricultura colombiana; paquetes IEEE 802.15.4; porcentaje de coincidencia del algoritmo de procesamiento de imágenes; matriz de confusión	0	15

14	Un sistema de clasificación de madurez de tomate rentable que utiliza procesamiento de imágenes para agricultores	SR Rupanagudi; BS Ranjani; P. Nagaraj; VG Bhat	2014	madurez de la fruta; etapas de crecimiento; procesamiento de imágenes; estimación de la madurez; clasificación de madurez; agricultura inteligente; clasificación de tomate	Análisis de color de imágenes; Cámaras; Precisión; Diseño y análisis de algoritmos; Iluminación; Segmentación de imágenes	agricultura, industria de procesamiento de alimentos, procesamiento de imágenes	sistema de clasificación de madurez de tomate rentable; madurez de la fruta; agricultores; industria de procesamiento de alimentos; pérdidas económicas; cadena de mercado; sistema de clasificación de madurez; material de bajo costo; algoritmos de procesamiento de imágenes	10	21
15	Un método de segmentación basado en reglas para imágenes de frutas bajo iluminación natural.	H. Hambali; N. Jamil; SLS Abdullah; H . Harun	2014	segmentación; umbralización; agrupamiento; entorno natural	Segmentación de imágenes; Análisis de color de imágenes; Segmentación de objetos; Algoritmos de agrupamiento; Algoritmos de procesamiento de señales; Iluminación; Silicio	Productos agrícolas; visión por computadora; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes	Método de segmentación de imágenes basado en reglas; imágenes de frutas; iluminación natural; sistema de visión artificial; sistema automático de clasificación de frutas; ambiente exterior; color de la superficie del objeto; clasificación de objetos; algoritmo IF-THEN	2	25
16	Clasificación automática de fruta utilizando algoritmo de bosque aleatorio	HM Zawbaa; M. Hazman;M. Abbass; AE Hassanien	2014	Clasificación de frutas; Clasificación de imágenes; Extracción de características; Transformación de características invariantes de escala (SIFT); Bosque aleatorio (RF)	Extracción de características; Forma; Análisis de color de la imagen; Exactitud; Radio frecuencia; Capacitación; Máquinas de vectores de soporte	Productos agrícolas; cámaras; extracción de características; clasificación de imágenes; análisis de color de imágenes; aprendizaje (inteligencia artificial); reconocimiento de formas; transformaciones	Clasificación automática de frutas; algoritmo de bosque aleatorio; enfoque de clasificación; algoritmo de RF; manzanas; fresas; naranjas; extracción de características; forma de frutas; características de color de frutas; transformación de características invariantes de escala; SIFT; procesamiento de imágenes; conjunto de datos de imágenes de frutas; índice de color; algoritmo de aprendizaje automático ; cámara digital normal; adquisición de imágenes; entorno MATLAB	5	21

17	Región no saludable de detección de hojas de cítricos mediante técnicas de procesamiento de imágenes	KR Gavhale; U. Gawande;K O Hajari	2014	cítricos; cancro; antracnosis; matriz de co-ocurrencia; SVM; característica de la textura	Análisis de color de imágenes; Enfermedades; Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Mejora de imágenes; Algoritmos de clasificación	Productos agrícolas; extracción de características; clasificación de imágenes; análisis de color de imagen; mejora de imagen; agrupamiento de patrones; análisis estadístico; máquinas de vectores de soporte	Región no saludable; detección de hojas de cítricos; técnicas de procesamiento de imágenes; productos agrícolas; enfermedades de plantas; características de las hojas; análisis de imágenes; técnicas de clasificación de imágenes; RGB; conversión del espacio de color; mejora de la imagen; agrupamiento de medias K; uso estadístico; extracción de características de textura; GLCM estadístico SVM	19	12
18	Evaluación de la frescura de los productos utilizando el aprendizaje por transferencia.	A. Lam; Y. Kuno; I. Sato	2015	-	Capacitación; Máquinas de vectores de soporte; Datos de capacitación; Estándares; Análisis de color de imagen; Correlación; Extracción de características	productos agrícolas; clasificación de imágenes; aprendizaje (inteligencia artificial); control de calidad; máquinas de vectores de soporte	producir evaluación de frescura, aprendizaje de transferencia, control de calidad automatizado, entrenamiento de clasificadores, clasificación de clasificadores	0	14
19	Clasificación automática de aceitunas para la producción de aceite mediante visión artificial.	DM Gila; DA Puerto; JG García; JG Ortega	2015	Clasificación de aceitunas; Visión artificial; Proceso de extracción de aceite de oliva	Suelo; Producción; Histogramas; Visión por ordenador; Análisis de color de imagen; Cámaras; Análisis de componentes principales	visión por ordenador, clasificación de imágenes, fresado, ingeniería de producción informática, aceites vegetales	Clasificación automática de aceitunas; visión artificial; producción de aceite de oliva; frutos de oliva; proceso de extracción de aceite; sistema de inspección automático; proceso de molienda; histogramas de imagen de oliva; técnicas de clasificación lineal; algoritmos de procesamiento de imagen; análisis discriminante de Fisher	1	12
20	Clasificación automática basada en visión artificial de tomates cherry.	V. Pavithra; R. Pounroja; B S Bama	2015	Clasificación; Tomates Cherry; Textura; color; forma; Segmentación del color; madurez	Extracción de características; Análisis de color de imagen; Forma; Máquinas de vectores de soporte; Clasificación; Algoritmos de clasificación; Color	Visión por ordenador, teoría de la estimación, extracción de características, productos alimenticios, clasificación de imágenes, análisis de color de imágenes, segmentación de imágenes, manejo de materiales, ingeniería de producción informática, máquinas de vectores de soporte	Visión artificial; clasificación automática; tomates cherry; vida en el mercado; clasificación no destructiva; grado de madurez; grado de calidad; algoritmo de estimación de la madurez basada en el color; superficie de tomate; segmentación basada en el color; distancia euclidiana; extracción de características; fruta madura; clasificador SVM; clasificador KNN; tiempo de cálculo	3	9

21	Sistema automático de clasificación y clasificación de frutas usando la visión por computadora: una revisión	Seema; A. Kumar; GS Gill	2015	Clasificación de frutas, visión artificial, características morfológicas, textura.	Análisis de color de la imagen; Exactitud; Extracción de características; Forma; Visión por computadora; Agricultura	Visión por computadora; cultivos; clasificación de imágenes; análisis de color de imagen; textura de imagen; comercio internacional; manejo de materiales; calidad del producto; productividad	Clasificación automática de la fruta; sistema de clasificación; visión por ordenador; agricultura; productividad; calidad del producto; crecimiento económico; evaluación de la calidad de la fruta; mercado de exportación; sistema inteligente de clasificación de la fruta; clasificación de la fruta; característica del color; característica de la textura; característica morfológica	5	35
22	Un método novedoso para personas con discapacidad visual mediante el reconocimiento de objetos.	R. Kumar; S. Meher	2015	Red neuronal convolucional; reconocimiento de color; agrupamiento k-means; clasificador softmax	Análisis de color de la imagen; Reconocimiento de la imagen; Voz; Reconocimiento de la voz; Índices; Cabeza; Yttrium	Procesamiento de señales de audio; visión por computadora; redes neuronales de avance; ayudas para discapacitados; clasificación de imágenes; análisis de color de imágenes; reconocimiento de objetos	Reconocimiento de la policía; reconocimiento del color de la fruta; reconocimiento del color de la ropa; conjunto de datos en línea; panel de botones de demanda; módulos del sistema; espacio de color HSI; red neuronal recursiva; red neuronal de convolución; teléfono móvil; método de asistencia; generación de retroalimentación de audio; visión artificial; módulo de reconocimiento de objetos personas con discapacidad visual	2	14
23	Histograma basado en la identificación del patrón de color de la fruta multiclase mediante la selección de características	E. Rachmawati ; ML Khodra;Yo supriana	2015	Histograma de color; selección de características de chi-cuadrado; K-Vecino más cercano; patrón de color	Análisis de color de imágenes; Histogramas; Extracción de características; Reconocimiento de objetos; Algoritmos de filtrado; Cuantización (señal); Escala de grises	Extracción de características; clasificación de imágenes; análisis de color de imágenes; filtrado de imágenes; representación de imágenes	Identificación de patrones de color basados en histogramas de frutas multiclase; método de filtro de selección de características; extracción de características; representación de características de color de objetos; rendimiento de clasificación de imágenes; clasificación de frutas; espacio de características; canal RGB; canal rojo-verde-azul; selección de características de chi cuadrado; vecino K-más cercano clasificador; clasificador KNN	4	18

24	Procesamiento de imágenes para la detección de la etapa de maduración del mango: método RGB y HSV	RP Salunkhe; A A Patil	2015	RGB; HS; detección de la etapa de maduración del mango; Alfonso; gradación del mango	Pruebas; análisis de color de la imagen.	Cultivos, análisis de color de la imagen, iluminación, detección de objetos	Procesamiento de imágenes; detección de la etapa de maduración del mango; método RGB; método HSV; frutas comerciales; industrias de procesamiento de mango; mango alfonso; píxeles de la imagen; mapa de valor de saturación de matiz; componentes rojo, verde y azul; luz blanca; luz natural; luz ambiental	2	5
25	Diagnóstico de enfermedades de la planta de granada mediante red neuronal.	M. Dhakate; Ing ole AB	2015	detección y clasificación de enfermedades; enfermedades de la planta de la granada; segmentación de agrupamiento de K-medias; método GLCM; red neuronal artificial	Enfermedades; Extracción de características; Algoritmos de clasificación; Microorganismos; Segmentación de imágenes; Capacitación; Algoritmos de agrupamiento	Cultivos; extracción de características; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; textura de imágenes; redes neuronales; detección de objetos; enfermedades de plantas	Diagnóstico de enfermedades de la planta de la granada; cultivo; procesamiento de imágenes; fitopatología; detección de enfermedades; clasificación de enfermedades; hongos; bacterias; condición climática; tizón bacteriano; mancha de frutos; podredumbre de frutos; mancha foliar; imagen en color; k-significa segmentación de agrupamiento; extracción de características de textura; Método GLCM; red neuronal artificial	7	13

26	Detección de frutas basada en la textura a través de imágenes utilizando los patrones suaves en la fruta.	ZS Pothen; S. Nuske	2016	-	Agricultura; Tuberías; Análisis de color de imagen; Iluminación; Resolución de imagen; Detectores; Forma	Agricultura; cultivos; clasificación de imágenes; filtrado de imágenes; resolución de imágenes; textura de imágenes; aprendizaje (inteligencia artificial); detección de objetos	Detección de frutas basada en textura; patrones de suavidad de frutas; algoritmo de detección de puntos clave; detección de frutas redondas; imágenes de alta resolución; uvas; manzanas; características de contraste; contorno de frutas; oclusión; color de frutas; follaje de fondo; variación de intensidad gradual; orientación de degradado; ubicación de frutas; puntos de semilla; filtro de imagen; clasificación; histograma modificado de gradientes orientados; descriptor de textura de comparación de intensidad por pares; clasificador de bosque aleatorio	9	18
27	Un marco para medir el nivel de infección en las vainas de cacao.	DS Tan; RN Leong; AF Laguna; CA Ngo; A. Lao; D. Amalin; D. Alvindia	2016	cacao; segmentación de imágenes; características de color; aprendizaje automático; segmentación de defectos; agricultura inteligente	Análisis del color de la imagen; Segmentación de la imagen; Máquinas de vectores de soporte; Enfermedades; Algoritmos de agrupamiento; Capacitación; Regiones	cultivos; análisis de color de la imagen; clasificación de patrones; informática de ingeniería de producción; máquinas de vectores de soporte	vainas de cacao; medición del nivel de infección; enfermedades; técnicos agrícolas; inspección visual; algoritmo k-means; máquina de vectores de soporte; SVM; colores de imagen; apoyo a la decisión	0	22

28	Un estudio comparativo de los métodos de extracción de características en la clasificación de defectos de mangos utilizando una red neuronal	V. Ashok; DS Vinod	2016	Defectos en el mango; Segmentación de imágenes; Características de textura; Red neuronal; Validación	Extracción de características; Segmentación de imágenes; Análisis de color de imágenes; Color; Algoritmos de clasificación; Piel; Minería de datos	Productos agrícolas; filtros de banco de canales; extracción de características; selección de características; clasificación de imágenes; análisis de color de imágenes; redes neuronales; análisis estadístico	Métodos de extracción de características; clasificación de defectos en el mango; red neuronal; NN; Mangifera indica L; variedad de mango Alphonso; imágenes en color; clases de calidad; preprocesamiento de imagen; extracción de características en la textura; algoritmo de selección progresiva secuencial; características estadísticas; LBP; bancos de filtros; modelo lineal generalizado clasificador	5	19
29	Identificación automática de defectos y sistema de clasificación para manzanas 'Jonagold'	S. Raj; DS Vinod	2016	Imágenes multiespectrales; Clasificación de frutas; Detección de defectos; Agrupación; Extracción de características; Clasificación	Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Análisis de color de imágenes; Capacitación; Algoritmos de agrupamiento; Histogramas	Productos agrícolas; extracción de características; teoría de conjuntos difusos; métodos de gradiente; clasificación de imágenes; segmentación de imágenes; agrupamiento de patrones; análisis espectral; máquinas de vectores de soporte	Clasificación multicategoría; MSVM; máquina de vectores de soporte multiclase; clasificación de manzana; HOG; histograma de gradientes orientados; segmentación de defectos; agrupación de FCM; agrupación difusa de medios C; imágenes multiespectrales; extracción de características de defectos; manzanas Jonagold; identificación automática de defectos	0	18
30	Modelo difuso optimizado de enjambre de partículas para la clasificación de la madurez del banano	S. Marimuthu; SMM Roomi	2017	Plátano; visión artificial; segmentación; espacio de color; modelado difuso; CARRITO; PSO; clasificación de maduración; matriz de confusión	Análisis de color de la imagen; Extracción de características; Color; Sensores; Máquinas de vectores de soporte; Lógica difusa	Productos agrícolas; sistemas difusos; optimización de partículas enjambres	Base de datos MUSA; algoritmo de árbol de regresión; CIELa * b *; área marrón normalizada; Matiz pico; etapas demasiado maduras; etapa madura; etapa inmadura; clasificación de madurez del banano; modelo borroso optimizado de enjambre de partículas	3	37

31	Identificación y conteo de manzanas maduras basadas en la red neuronal de BP feed forward	S. Lal; SK Behera; PK Sethy; AK Rath	2017	Aprendizaje automático; RGB; clasificación; extracción de características; Red neuronal de avance de propagación hacia atrás	Análisis del color de la imagen; Extracción de características; Redes neuronales biológicas; Algoritmos de procesamiento de señales; Agricultura; Algoritmos de clasificación	Extracción de características; redes neuronales de alimentación directa; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; aprendizaje (inteligencia artificial)	Conteo de fruta madura; identificación de fruta madura; BP alimenta la red neuronal; clasificación de la fruta; detección de la fruta; observación a simple vista; fatiga ocular; procesamiento de imágenes; aprendizaje automático; extracción de componentes de color de manzana; red neuronal artificial; componentes de color de manzana inmaduro; componentes	0	15
32	Reconocimiento automático de frutas a partir de imágenes naturales con características de color y textura.	S. Jana; S. Basak; R. Parekh	2017	segmentación; reconocimiento; GLCM; color; SVM	Análisis de color de imágenes; Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Circuitos integrados; Capacitación; Diseño y análisis de algoritmos	Productos agrícolas; visión por computadora; sistemas integrados; extracción de características; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; textura de imágenes; aprendizaje (inteligencia artificial); clasificación de patrones; máquinas de vectores de soporte	Reconocimiento automático de la fruta; imágenes naturales; características de la textura; recolección automatizada asistida por robot; visión por ordenador; inteligencia de la máquina; cadena de producción más rápida; cosecha automática; descriptor de una sola característica; modelo de clasificación de máquinas de vectores de soporte; descriptores de características; imagen sin etiqueta; segmentación de la imagen; gris de alto nivel de co-ocurrencia; GLCM; extracción estadística de características de color; sistemas integrados	3	12

33	Detección automática de moretones en tiempo real en frutas (Apple) usando una cámara térmica	D. Jawale; M. Deshmukh	2017	Red neuronal artificial (ANN); Matriz de coexistencia de nivel de grises (GLCM); K-significa segmentación de agrupamiento; imágenes térmicas	Segmentación de imágenes; Extracción de características; Algoritmos de agrupamiento; Diseño y análisis de algoritmos; Algoritmos de clasificación; Análisis de color de imagen; Estándares	Productos agrícolas; cámaras; enfermedades; industria de procesamiento de alimentos; productos alimenticios; tecnología de alimentos; clasificación de imágenes; segmentación de imágenes; imágenes infrarrojas; inspección; redes neuronales; control de calidad; sistemas en tiempo real; análisis estadístico	Economía agrícola; método de procesamiento de imágenes modernizado; enfermedades de la fruta; K-significa segmentación de agrupamiento; matriz de coexistencia de nivel de grises; red neuronal artificial; automatización en tiempo real; sistema automático de detección de contusiones; tarea de inspección de personas; industria de poscosecha; método de clasificación tradicional; térmica imagen de la cámara; frutas de manzana	0	16
34	Recuperación de imágenes basada en contenido para el reconocimiento de frutas de múltiples objetos utilizando k-means y k-vecino más cercano	Erwin M. Fachrurrozi; A. Fiqih; BR Saputra; R. Algani; A. Primanita	2017	Objeto múltiple; Extracción de características; Histograma de color difuso; Momento invariante; Agrupamiento de medios K-K; Clasificación K-NN; CBIR		Recuperación basada en contenido; extracción de características; análisis de color de imagen; recuperación de imagen; método de momentos; reconocimiento de objetos; reconocimiento de formas	Recuperación de imágenes basada en contenido, reconocimiento de frutas multiobjetos, vecino k más cercano, proceso de extracción de color, método de histograma de color difuso, FCH, extracción de conformación, método Invariants de Moment, método k-NN, proceso de recuperación de imágenes basado en contenido, características de imagen, contenido visual; búsquedas de imágenes; sistema de reconocimiento de frutas; imágenes de un solo objeto; imagen multiobjeto; algoritmo de agrupamiento de k-means; proceso CBIR	1	23
35	Identificación del tamaño y madurez de la fruta a través de imágenes de frutas utilizando OpenCV-Python y	IB Mustaffa; S FBM Khairul	2017	madurez de la fruta; tamaño de la fruta; índice de color; Rasberry Pi; OpenCV-Python	Análisis de color de imágenes; Histogramas; Índices; Visión por computadora; Medición de tamaño; Algoritmos de agrupamiento	Productos agrícolas; visión por computadora; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; agrupamiento de patrones	Algoritmo de procesamiento de imágenes; identificación del tamaño de la fruta; agrupamiento de K-medias; clasificación de madurez de la fruta; evaluación manual; agricultores de negocios; OpenCV-python; imágenes de la fruta; color de la fruta; Raspberry Pi; fruta del mango; índices de madurez; observación visual	1	7

36	Clasificación de imágenes basada en la región utilizando técnicas de transformación de cuencas hidrográficas.	MS Pawar; L. Perianayagam; NS Rani	2017	Clasificación de imágenes; frutas y verduras; transformación de cuencas hidrográficas; características de wavelet de Haar; enfoque de clasificación basado en la votación	Segmentación de imágenes; Transformaciones; Clasificación de imágenes; Extracción de características; Detección de bordes de imágenes; Análisis de color de imágenes; Recuperación de información	Métodos de Bayes; extracción de características; transformaciones de Haar; clasificación de imágenes; segmentación de imágenes; recuperación de información; métodos de vecino más cercano; reconocimiento de formas; máquinas de vectores de soporte; transformadas de wavelets	recuperación de información; datos de tipo de texto; datos multimedia; características regionales; técnica basada en votación; clasificación de imágenes basada en regiones; transformación de cuencas hidrográficas; recuperación de datos; gestión de datos; características de forma; segmentación de imágenes; características de wavelet Haar; clasificador KNN; clasificador SVM; clasificador Naïve Bayes	0	10
37	Reconocimiento de la condición madura, inmadura y escalada de los cítricos anaranjados según la clasificación del árbol de decisión	A. Wajid; NK Singh; P. Junjun; MA Mughal	2018	Fruta naranja; Clasificación de cítricos; Madura e inmadura; Procesamiento de imágenes; Árbol de decisiones; BIC	Árboles de decisión; Extracción de características; Análisis de color de imagen; Redes neuronales artificiales; Segmentación de imágenes; Industrias	Productos agrícolas; métodos Bayes; visión por computadora; árboles de decisión; extracción de características; industria de procesamiento de alimentos; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; redes neuronales; computación de ingeniería de producción	Frutas cultivadas; industrias de procesamiento de alimentos; pulpa de naranja; condición de naranja; características de la imagen de la fruta; espacio de color RGB; Naïve Bayes; técnicas de visión por ordenador; reconocimiento de cítricos de naranja; clasificación de píxeles del borde / interior; técnica de clasificación de árboles de decisión; red neuronal artificial	1	15
38	Clasificación basada en el procesamiento de imágenes de pardeamiento enzimático en manzanas picadas	M. Arora; MK Dutta; CM Travieso; R. Burget	2018	manzana troceada; procesamiento de imágenes; pardeamiento enzimático; característica estadística discriminatoria; dominio wavelet; valor p	Segmentación de imágenes; Extracción de características; Análisis de color de imágenes; Dominio de ondulación; Algoritmos de agrupamiento; Cámaras	productos alimenticios; clasificación de imágenes; procesamiento de imágenes; aprendizaje (inteligencia artificial); análisis estadístico; máquinas de vectores de soporte	máquina de vectores de soporte basado en aprendizaje automático; clasificador SVM; características estadísticas; clasificación basada en procesamiento de imágenes; algoritmo de procesamiento de imágenes; manzanas picadas; pardeamiento enzimático	0	20

39	Sistema de reconocimiento de especies de durian basado en representaciones de formas globales y vecinos K-Nearest	XY Nyon; MR Mustaffa; L N Abdullah; N A Nasharuddin	2018	Durian; Basado en contenido; Característica de forma; K-vecinos más cercanos; Tasa de reconocimiento; 10 veces la validación cruzada	Análisis de color de imágenes; Extracción de características; Forma; Reconocimiento de imágenes; Bases de datos; Pruebas; Capacitación	Productos agrícolas; extracción de características; clasificación de patrones; reconocimiento de formas	sistema de reconocimiento de especies de durian; representaciones de formas globales; sistema de reconocimiento de frutas basado en contenido; descriptores de formas basados en regiones; vecino más cercano al k; descriptor de formas basado en contornos globales; extracción de características	0	12
40	Detección de café (Coffea Arabica L.) eventos de floración secuencial basados en la segmentación de la imagen	H. Peng; J. Huang; H. Jin;H. sol; D. Chai; X. Wang; B. Han; Z. Zhou; L. Xu	2018	eventos de floración de café; fusión de superpíxeles; segmentación de flores; momento de color; patrones binarios locales; máquina de vectores de soporte	Segmentación de imágenes; Máquinas de vectores de soporte; Superficies selectivas de frecuencia; Capacitación; Fusión; Análisis de color de imágenes; Detección de eventos	productos agrícolas; cámaras; extracción de características; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; detección de objetos; máquinas de vectores de soporte; series de tiempo	imágenes digitales de la serie temporal de alta velocidad; imágenes RGB; ángulos de depresión; imágenes multitemporales de tiempo de disparo; detección del día de floración; tiempo de maduración; plantación de café; cámara digital; sensor; ángulos de azimut; segmentación de súper píxeles de igual tamaño; subsiguiente proceso de fusión de súper píxeles; vectores de características ; operador de los momentos de color; operador de patrones binarios locales; clasificador de la máquina de vectores de soporte; umbral; recuperación; precisión; intersección sobre la unión; IoU; estimación del rendimiento; predicción de la madurez de la fruta del café; ángulo de depresión óptimo; algoritmo de segmentación de la flor; densidad de la flor basada en la imagen; flor proporción; píxeles de la flor; regiones de la flor; período de floración del café; método de segmentación de la flor basada en regiones multiescala; estimación de la densidad de la flor; detección de eventos de floración secuencial del café; segmentación de la imagen	0	22

41	Método de clasificación de Apple basado en características de color y defecto	Y. Ji; Q. Zhao; S. Bi; T. Shen	2018	Procesamiento de imágenes; Visión por computadora; Extracción de características; Detección de defectos; SVM; Clasificación	Análisis de color de imágenes; Extracción de características; Máquinas de vectores de soporte; Detección de bordes de imágenes; Segmentación de imágenes; Algoritmos de clasificación; Visión artificial	productos agrícolas; visión por computadora; detección de bordes; extracción de características; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; optimización de enjambres de partículas; máquinas de vectores de soporte	método de clasificación de manzanas; tecnología de visión artificial; detección de productos agrícolas; algoritmo Oust; valores H; característica de color; algoritmo de detección de bordes Canny; imagen de fruta; color de manzana; imágenes de manzana basadas en RGB; modelo HIS; optimización de enjambre de partículas; SVM	0	8
42	Clasificación de enfermedades y clasificación de naranja mediante aprendizaje automático y lógica difusa	SK Behera; L. Jena; AK Rath; PK Sethy	2018	K-significa agrupamiento; clasificación de enfermedades; lógica difusa; SVM de clases múltiples	Enfermedades; Extracción de características; Análisis de color de imagen; Segmentación de imagen; Máquinas de vectores de soporte; Algoritmos de clasificación; Lógica difusa	productos agrícolas; computación de biología; visión por computadora; enfermedades; lógica difusa; aprendizaje (inteligencia artificial); agrupamiento de patrones; máquinas de vectores de soporte	lógica difusa; fruta naranja; tipo de defecto; marca de defecto; gravedad de la enfermedad; visión por ordenador; aprendizaje automático; clasificación de la naranja; clasificación de la enfermedad; contaminación ambiental; carga económica; SVM; agrupación de K-means	0	18
43	Clasificación de la calidad y madurez de los mangos cosechados según las técnicas de aprendizaje automático	D. Pise; GD Upadhye	2018	Bytes ingenuos; Clasificación; Calidad; SVM; RGB; Análisis posterior y madurez	Análisis de color de la imagen; Forma; Máquinas de vectores de soporte; Algoritmos de clasificación; Extracción de características; Clasificación; Núcleo	productos agrícolas; industria de procesamiento de alimentos; productos alimenticios; aprendizaje (inteligencia artificial); probabilidad; calidad del producto; rentabilidad; máquinas de vectores de soporte	método de aprendizaje automático; análisis posterior; calidad de mangos cosechados; máquina de vectores de soporte; ganancias; campo agrícola; industria alimentaria; probabilidad	0	11

44	Visión de máquina en tiempo real de alta precisión para la medición de diámetros usando el algoritmo Simpson	TK Hariadi; H. Zidni; KT Putra; S. Riyadi	2018	medición de tamaño; visión de cámara; medición automática; clasificación de tamaño; algoritmo de simpson	Calibración; Medición de tamaño; Cámaras; Análisis de color de imagen; Confiabilidad; Medición de área; Incertidumbre de medición	calibración; cámaras; visión artificial; instrumentación computarizada; medición del diámetro	Algoritmo de Simpson; medición de calidad; clasificación de frutas; medición de precisión; tecnología láser; medición en tiempo real; procesamiento de imágenes; método de medición de diámetro; cámara regular; medición de alta precisión; alta velocidad de cálculo; alta precisión en tiempo real visión de la máquina	0	18
45	Detección de Canarium Ovatum (Pili) maduro mediante el clasificador Adaboost y el análisis de color	JNB Capucao; T D Palaoag	2018	Canarium ovatum; adaboost; análisis de color	Análisis de color de la imagen; Extracción de características; Algoritmos de clasificación; Capacitación; Iluminación; Agricultura; Aprendizaje automático	Vehículos aéreos autónomos; cultivos; extracción de características; captura de imágenes; clasificación de imágenes; análisis de color de imágenes; resolución de imágenes; textura de imágenes; detección de objetos	ovario de canario maduro; clasificador adaboost; análisis de color; región bicol; cultivo indígena; detección de frutas; procesos de postproducción; dron de gama alta; Phantom 4 Professional; detección de pili maduro; sistema de visión; características similares a Haar	0	15

46	Técnica de detección de calidad mejorada para frutas que utilizan GLCM y MultiClass SVM	AA Chandini; U M B	2018	Detección de defectos; clasificación de defectos; Raspberry Pi; GLCM; MultiClass SVM	Extracción de características; Análisis de color de imagen; Cámaras; Segmentación de imagen; Matlab; Hardware	productos agrícolas; inspección óptica automática; extracción de características; productos alimenticios; captura de imágenes; clasificación de imágenes; segmentación de imágenes; inspección; aprendizaje (inteligencia artificial); ingeniería de producción informática; control de calidad; máquinas de vectores de soporte	técnica de detección de la calidad de la fruta; GLCM; SVC multiclase; inspección; algoritmo de aprendizaje automático; Raspberry Pi; Matlab; captura de imágenes; segmentación de imágenes; extracción de características; clasificación de imágenes; empresas de fabricación de alimentos; verduras; técnicas de procesamiento de imágenes	0	14
47	Conteo robusto de frutas: combinación de aprendizaje profundo, seguimiento y estructura desde el movimiento	X. Liu; SW Chen; S. Aditya;N. Sivakumar; S. Dcunha;C. Qu; CJ Taylor; J. Das; V. Kumar	2018	-	Segmentación de imágenes; Seguimiento; Pantallas tridimensionales; Tuberías; Secuencias de imágenes; Aprendizaje profundo; Cámaras	cámaras; visión por computadora; extracción de características; clasificación de imágenes; análisis de color de imágenes; análisis de movimiento de imágenes; segmentación de imágenes; secuencias de imágenes; filtros de Kalman; detección de objetos; seguimiento de objetos; estimación de posturas; procesamiento de señales de video	Algoritmo de movimiento; pistas de fruta de doble conteo; conteos visuales anotados por humanos, verdades terrestres; canalización de conteo de frutas; canalización de conteo de frutas; proceso de rastreo; rastreador de Kanade-Lucas-Tomasi; algoritmo húngaro; píxeles de no fruta; imágenes de fotogramas de segmentos de video; secuencias de imágenes trabajos; frutas visibles; seguimiento del cuadro; segmentación profunda; aprendizaje profundo; conteo robusto de frutas; precisión de conteo; secuencias de imágenes	1	22
48	Conteo de manzanas utilizando redes neuronales convolucionales	N. Häni; P. Roy; V. Isler	2018	-	Análisis del color de la imagen; Estimación del rendimiento; Agricultura; Segmentación de la imagen; Algoritmos de agrupamiento; Análisis de tareas; Vegetación	productos agrícolas; redes neuronales convolucionales; procesos gaussianos; horticultura; clasificación de imágenes; detección de objetos	estudios hortícolas, planificación logística, modelo de mezcla gaussiana, red neuronal convolucional, estimación del rendimiento, precisión por imagen, conteo de frutas, detección de frutas, conteos de vegetales, conteo de manzanas	0	18

49	Un algoritmo modificado de detección de borde de Canny para detección y clasificación de frutas	MK Monir Rabby; B. Chowdhury; JH Kim	2018	Detección de bordes: Algoritmo de detección de bordes modulares (CED) y Algoritmo de detección de bordes modulares modificados (MCED)	Detección de bordes de imagen; Análisis de color de imagen; Extracción de características; Algoritmos de clasificación; Forma; Clasificación	detección de bordes, extracción de características, análisis de color de imagen, reconocimiento de objetos	Algoritmo modificado de detección de borde Canny; método de reconocimiento de frutas; color; frutas; análisis de conjuntos de datos de entrenamiento; método de procesamiento de imágenes; clasificación de frutas; detección de frutas	0	6
50	Una clasificación automatizada de la calidad del tomate utilizando una máquina de vectores de soporte basada en agrupación	SS Deulkar; SS Barve	2018	Clasificación del tomate; Máquina de vectores de soporte; Visión por ordenador; Clasificación; Agrupación	Análisis de color de imagen; Máquinas de vectores de soporte; Extracción de características; Visión artificial; Cámaras; Algoritmos de clasificación	productos agrícolas; inspección óptica automática; visión por ordenador; extracción de características; industria de procesamiento de alimentos; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; pruebas no destructivas; ingeniería de producción informática; control de calidad; máquinas de vectores de soporte	sistema de clasificación automatizado no destructivo; clasificación de grado de fruta; visión de máquina automatizada; industria de procesamiento de alimentos; evaluación de calidad de fruta; máquina de vectores de soporte; método de clasificación de calidad de tomate automatizado; sector agrícola; algoritmos de agrupamiento K-Means; método de cosecha posterior; captura de imagen de fruta; cámara digital ; varias técnicas de procesamiento de imágenes; madurez de la fruta; características de color; umbral de Otsu; extracción de características	0	26

51	Clasificación de la fruta de grosella espinosa del cabo según su nivel de madurez utilizando técnicas de aprendizaje automático y diferentes espacios de color	W. Castro; J. Oblitas; M. De-La-Torre; C. Cotrina; K. Bazán; H. avila-george	2019	Grosella espinosa de cabo; redes neuronales artificiales; máquinas de vectores de soporte; árboles de decisión; vecinos más cercanos a K; espacios de color; PCA; matriz de confusión multiclase	Análisis de color de imágenes; Electrónica aeroespacial; Máquinas de vectores de soporte; Visualización; Segmentación de imágenes; Inspección; Instrumentos	productos agrícolas; árboles de decisión; industria de procesamiento de alimentos; productos alimenticios; clasificación de imágenes; métodos iterativos; aprendizaje (inteligencia artificial); redes neuronales; análisis de componentes principales; calidad del producto; máquinas de vectores de soporte	diferentes espacios de color; técnicas de aprendizaje automático; máquinas de vectores de soporte; imagen de la fruta; nivel de madurez; muestras de fruta de grosella del Cabo; redes neuronales artificiales; árboles de decisión; algoritmo del vecino K más cercano; estrategia de validación cruzada quíntuple; proceso iterativo; análisis de componentes principales; multiclase matriz de confusión; clasificación de frutas	1	54
52	Un método optimizado para la segmentación y clasificación de las enfermedades de la manzana basadas en una fuerte correlación y en la selección de características basadas en algoritmos genéticos	MA Khan; MIU Lali; M. Sharif; K. Javed; K. Aurangzeb; SI Haider; AS Altamrah; T. Akram	2019	Mejora de los síntomas; segmentación de los síntomas; extracción de características; características óptimas; reconocimiento	Enfermedades; Extracción de características; Análisis de color de imagen; Segmentación de imagen; Algoritmos genéticos; Lesiones; Máquinas de vectores de soporte	productos agrícolas; agricultura; algoritmo de expectativa-maximización; extracción de características; seguridad alimentaria; algoritmos genéticos; clasificación de imágenes; segmentación de imágenes; inspección; filtros de mediana; enfermedades de plantas; máquinas de vectores de soporte	seguridad alimentaria; industria agrícola; inspección manual; enfermedades de las plantas; segmentación del punto; extracción de las características; manchas de la hoja de la manzana; M-SVM; reconocimiento de la enfermedad; reconocimiento de la enfermedad; filtrado de cajas 3D; precisión de clasificación; enfermedades de la manzana; pérdidas económicas; algoritmo genético basado en la selección de funciones ; fusión paralela basada en la comparación; características de patrones binarios locales; histograma de color; segmentación de maximización de expectativa; filtro de mediana 3D; filtro gaussiano 3D	0	35

53	Recuento automático y tamaño individual y estimación en masa de olivos a través de técnicas de visión artificial.	JM Ponce; A. Aquino; B. millan; JM Andújar	2019	Visión por computadora; modelado de funciones; industria alimentaria; clasificación de frutas; análisis de imágenes; oliva	Análisis de imágenes; Modelado computacional; Extracción de características; Estimación; Visión por computadora; Industrias; Segmentación de imágenes	productos agrícolas; visión por computadora; extracción de características; industria de procesamiento de alimentos; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; segmentación de imágenes; morfología matemática; patentes; calidad del producto	técnicas de visión artificial; industria de la aceituna; aceitunas de mesa de alta calidad; clasificación de fruto de aceituna; algoritmo de análisis de imágenes; máquinas de clasificación de aceitunas no invasivas;	0	33
54	Clasificación del tomate según la madurez organoléptica (coloración) mediante algoritmos de aprendizaje automático K-NN, MLP y K-Means Clustering	WDN Pacheco; FR J López	2019	Clasificación de tomate; Procesamiento digital de imágenes; aprendizaje automático; K-NN; MLP; agrupamiento K-means	Algoritmos de clasificación; Análisis de color de imagen; Algoritmos de agrupamiento; Histogramas; Bases de datos; Estándares; Iluminación	productos agrícolas; quimiocepción; análisis de datos; productos alimenticios; clasificación de imágenes; análisis de color de imágenes; procesamiento de imágenes; álgebra matricial; perceptrones multicapa; métodos del vecino más cercano; clasificación de patrones; estándares; aprendizaje no supervisado	estándares internacionales; algoritmos de clasificación entrenados; clasificación de tomate; características físicas de la fruta; técnicas de procesamiento de imágenes digitales; algoritmo de aprendizaje no supervisado; madurez organoléptica; algoritmo de aprendizaje automático; algoritmo de clasificación supervisada; vecinos más cercanos a K; perceptrón multicapa; matriz de confusión global; análisis de datos	0	16

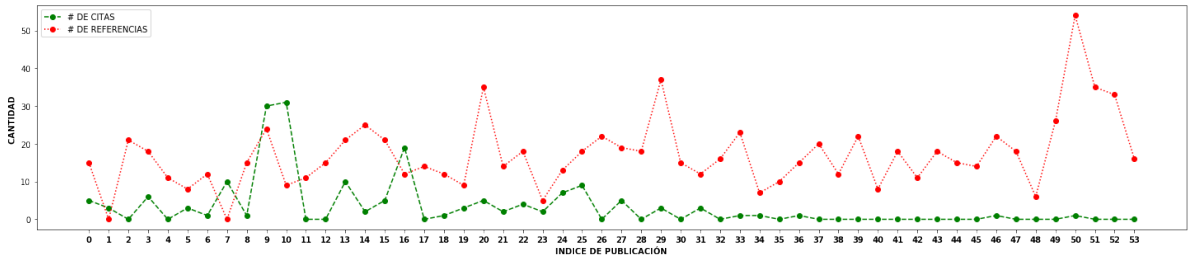

Figura 2.4: Valoración de los artículos según el número de citas y la cantidad de referencias
Fuente: Elaboración propia

2.3 Documentación dela investigación

El objetivo de la fase 3 es documentar las respuestas a las preguntas de investigación presentadas en el paso 1, así como validar el informe.

2.3.1 Validar el informe

Los datos y el análisis de esta revisión integradora fueron validados en todo momento por los autores de este documento como parte del proceso de revisión.

3. RESULTADOS

La interpretación de los resultados obtenidos se basa en la revisión bibliográfica de los artículos relacionados a la clasificación no destructiva de frutas según su estado de madurez utilizando visión por computador. A continuación, se muestra en la Figura 3.1 la cantidad de estudios relacionados al tema antes mencionado ordenados de forma ascendente por año de publicación utilizando la regla de búsqueda [2.1] para aplicar dicho filtro. Cabe mencionar que se evidencia un crecimiento constante salvo en años 2013 y 2016 en los cuales muestran un desfice en el aporte de las publicaciones relacionadas. Así mismo, se demuestra un crecimiento muy importante en los últimos años, lo cual demuestra que la clasificación automatizada de frutas se a convertido en un materia de investigación constante con un impacto muy importante en la agricultura.

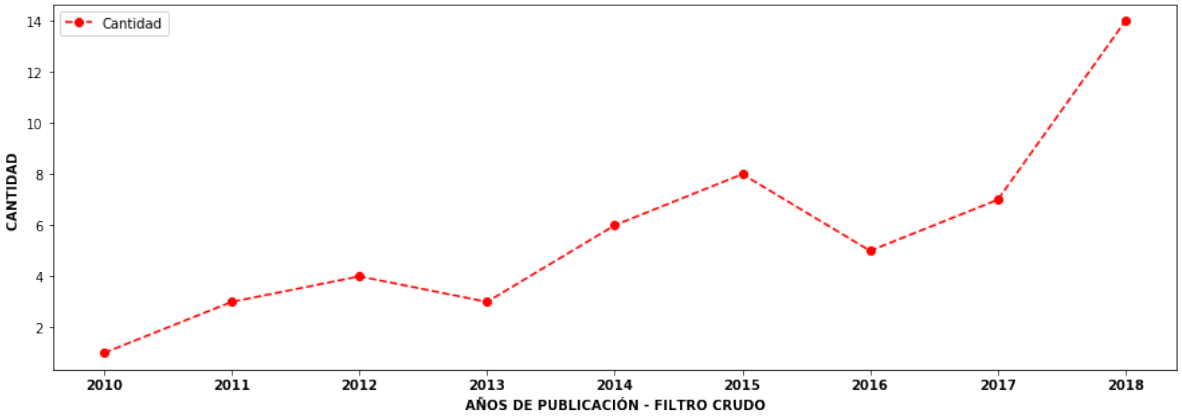

Figura 3.1: Cantidad de artículos por año aplicando el filtro crudo tal cual arroja la regla de búsqueda. **Fuente:** Elaboración propia

Los 54 documentos sobre clasificación automatizada de frutas elegidos para este proyecto se muestran en la Tabla 3.1. La cual es el resultado del análisis del contenido de las palabras clave las cuales sirven como descriptores críticos de cada documento para su selección, además de su

eficiencia en términos de porcentaje final de cada uno de ellos detallando la o las características con las cuales se extrae la información utilizada para realizar la clasificación automatizada de frutas.

Es importante señalar que los trabajos seleccionados otorgan datos puramente relacionados a la clasificación automatizada de frutas utilizando visión por computadora (es decir, si las propuestas realizan la clasificación de frutas utilizando alguna técnica relacionada al hardware, entre otros, el estudio no se incluyó en esta revisión).

3.1 Análisis

En esta sección se presentan los resultados de la análisis respondiendo a las preguntas de la investigación planteadas anteriormente [2.1.1] desarrollado como parte de esta literatura integradora proceso de revisión.

PRE 1. ¿Cuánto material bibliográfico relacionado a la clasificación de frutas utilizando visión artificial se ha publicado entre el año 2010 y 2018?

Si bien es cierto dar una valoración objetiva genérica de la cantidad de material bibliográfico existente relacionado a la clasificación automatizada no destructiva de frutas es muy amplia ya que depende la infinidad de base de datos donde se alojen cada propuesta es por ello que para realizar la propuesta de revisión se hace estricto énfasis en las dos revistas de IEEE filtrando los artículos de acuerdo a la regla de búsqueda planteada. A continuación se muestra el resultado del filtro y su valoración en la Tabla 3.1, en la cual se evidencian los 54 documentos de revistas encontrados en esta búsqueda integradora relacionada a la clasificación automatizada de frutas utilizando ciertas características (forma, color y textura). Además, se muestra la eficiencia en términos de porcentaje y la o las características trabajadas en cada documento las cuales son contribuciones clave de cada uno de estos. Es por ello que si una contribución clave en particular es de interés, puede ser igualada a su factor de impacto diario descrito anteriormente en la Tabla 2.3.

Nº	Año	Fruta	Característica	Eficiencia	Ref.
1	2010	Carambola	Color	96%	[1]
2	2010	Limón	Color y tamaño	94.04%	[12]
3	2010	Fresa	Forma y color	90%	[13]
4	2011	Manzana	Color	83.3%	[34]
5	2011	Manzana	Color (algoritmo EM)	91.72%	[3]
6	2011	Manzanas, plátanos, zanahorias, mangos y naranjas	Forma y color	79-90%	[14]
7	2011	Manzana	Color (algoritmo C-Means)	96%	[8]
8	2012	Manzana	Forma y color	90%, 88.8%	[17]
9	2012	Manzana, chikoo, naranja, mango y limón dulce	Color y textura	94%, 93%, 93%, 92% y 92%	[15]
10	2012	Mozafati	Color	86%	[16]
11	2012	Manzana	Color	100%	[17]
12	2012	Mango	Color y textura	80%	[18]
13	2012	Manzana	Color	100%	[4]
14	2012	Mango	Color	90.91%	[5]
15	2012	Naranjas, Mandarinas, manzanas, limones y tomates	Color	88%	[9]
16	2012	Manzana	Color	95.24%	[19]
17	2013	Naranja	Forma, intensidad y textura.	100%, 92% y 96%	[20]
18	2013	Grosella	Color y textura	90%	[7]
19	2013	Almendras	Color	88%	[31]
20	2013	Uva y manzana	Color, textura y morfología	90%	[10]
21	2014	Palta	Color, forma	82,22%	[43]
22	2014	Tomate	Color, textura	98%	[32]
23	2014	Manzana, Fresa y Naranja	Color, textura	92.31%	[11]
24	2015	Guayaba	Color	100%	[23]
25	2015	Aceituna	Color	100%	[46]
26	2015	Mango	Color	90.4%, 84.2%	[50]
27	2015	Granada	Color	90%	[51]
28	2016	Manzana	textura	80%,82%	[52]
29	2016	Cacao	Color	89.2%	[53]
30	2016	Mango	Color y textura	90.09%, 90.26%,90.26%	[38]
31	2016	Manzana	Color y textura	97.5%, 94.66%	[24]
32	2016	Uva y Manzana	Color	80%, 82%	[52]
33	2016	Manzana	Color, forma y textura	89.5%	[75]
34	2017	Banano	Color	93.11%	[54]
35	2017	Manzana	Color	98.1%	[55]
36	2017	Frutas	Color y textura	96%	[56]
37	2017	Frutas	Forma y color	92.5%,90%	[58]

38	2017	Frutas	Forma y color	90%	[59]
39	2017	Manzanas	Color	91.66%	[76]
40	2017	Pera	Color	93.4%	[28]
41	2017	Frutas y hortalizas	Color	95.6%	[77]
42	2018	Naranja	Color y forma	93.13%, 93.45% y 93.24%	[60]
43	2018	Manzana	Color	85%	[61]
44	2018	Durian	Forma, color	100%	[62]
45	2018	Café	Color	81.81%	[63]
46	2018	Manzana	Color	91%	[64]
47	2018	Naranja	Color	91%	[65]
48	2018	Frutas	Color, textura y forma	93%-99%	[67]
49	2018	Canarium Ovatum (Pili)	Color	90.77%	[68]
50	2018	Manzana	Color	96-97%	[71]
51	2018	Frutas	Color	91.44%	[70]
52	2018	Frutas	Color y textura	95,3%	[21]
53	2018	Frutas	Color	94%	[27]
54	2018	Manzana	Color	90%	[78]

Tabla 3.1: RESULTADOS MAS SIGNIFICATIVOS SOBRE CLASIFICACIÓN AUTOMATIZADA DE FRUTAS, 2010 - 2018. **Fuente:** Elaboración propia

Año de la publicación de los artículos								
2010	**2011**	**2012**	**2013**	**2014**	**2015**	**2016**	**2017**	**2018**
3	4	9	4	3	4	6	8	14

Tabla 3.2: CANTIDAD DE ARTÍCULOS PUBLICADOS SOBRE CLASIFICACIÓN AUTOMATIZADA DE FRUTAS ENTRE EL AÑO 2010 - 2018 **Fuente:** Elaboración propia

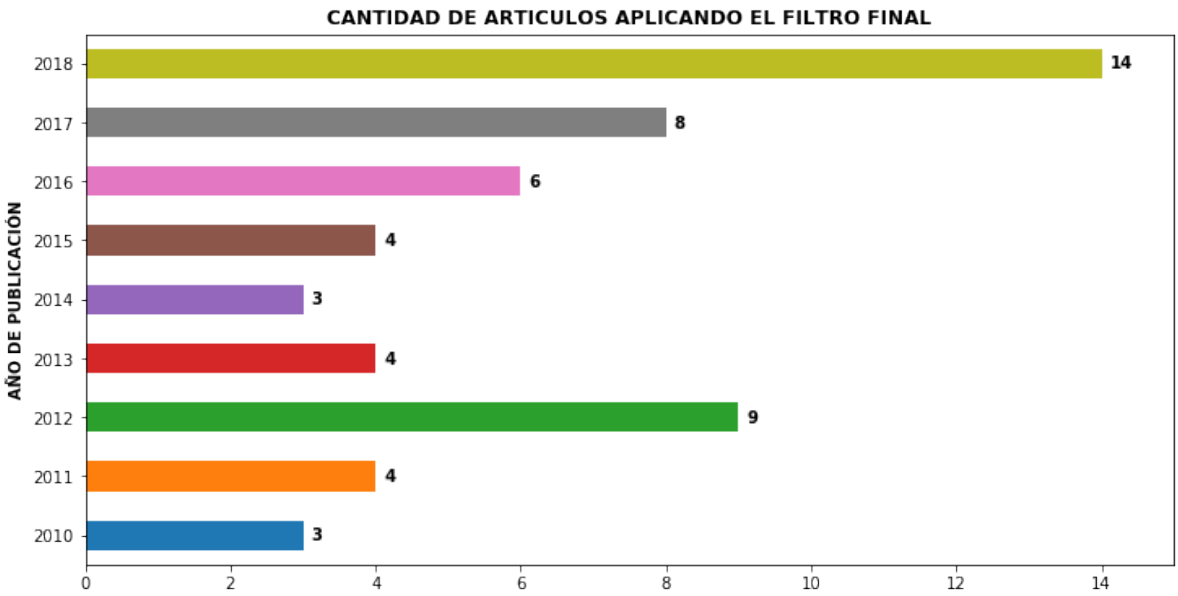

Figura 3.2: Tendencia de la cantidad de publicaciones de los artículos aplicando el filtro final según el protocolo de revisión

PRE 2. ¿Cuál es la técnica predominante para realizar el procedimiento de clasificación de frutas?

El resultado del análisis demuestra que la técnica predominante por excelencia para realizar la clasificación de frutas de manera no destructiva utilizando aprendizaje automático es el **procesamiento de imágenes** la cual ha venido ganando muchísimo terreno en el mundo de la inteligencia artificial relacionada a la investigación aplicada por ser sumo interés en áreas ya sea para el reconocimiento biométrico, extracción de características, entre otras. A continuación, se muestra una tabla en la cual se especifica el título del artículo, año de publicación, términos controlados por IEEE para dar fe del uso de la técnica y una valoración lógica del uso de la técnica. Se puede dar fe que esta técnica es una especie de estar para realizar este tipo de investigaciones ya como se puede evidenciar que todos los artículos filtrados por la regla de búsqueda según el protocolo establecido utilizan el procesamiento de imágenes.

EVIDENCIA DEL USO DE LA TECNICA DE PROCESAMIENTO DE IMÁGENES RELACIONADO A LA CLASIFICACIÓN AUTOMATIZADA DE FRUTAS			
Titulo del documento	**Año**	**Términos de IEEE**	**Proc. de Imágenes**
Clasificación de madurez de color de Starfruit usando Cr como característica	2010	Análisis de color de la imagen; algoritmos de clasificación; modelo matemático; índices; ecuaciones; formación; extracción de características	Si
Clasificación de frutas basadas en color utilizando GPU	2011	Java; Comunicación móvil; Bases de datos; Sol; Comunicación inalámbrica; Servidores; Asistentes digitales personales	Si
Detección de defectos de Apple utilizando algoritmo EM basado en histograma estadístico	2011	Análisis de color de imágenes; Segmentación de imágenes; Píxeles; Histogramas; Precisión; Algoritmos de clasificación	Si
Detección de defectos de Apple mediante el uso de histograma estadístico basado en un algoritmo difuso de medios C	2011	Análisis del color de la imagen; Segmentación de la imagen; Algoritmos de agrupamiento; Algoritmos de clasificación; Histogramas; Color	Si
Un método basado en FCM para reconocer y extraer tomate maduro para el sistema robótico de cosecha	2012	Análisis del color de la imagen; Segmentación de la imagen; Algoritmos de agrupamiento; Reconocimiento de la imagen; Morfología; Color; Forma	Si
Clasificador Multi Class Support Vector Machines para aplicación de visión artificial.	2012	Máquinas de vectores de soporte; Kernel; Capacitación; Visión artificial; Exactitud; Algoritmos de clasificación; Análisis de color de imagen	Si
Clasificación de mangos por características de objeto y modelado de contorno.	2012	Extracción de características; Segmentación de imágenes; Forma; Análisis de color de imágenes; Polinomios; Algoritmos de clasificación; Industrias	Si
Clasificación de objetos sólidos con formas definidas utilizando visión estereoscópica y un brazo robótico	2012	Resúmenes; Procesamiento de imagen estéreo; Forma; Análisis de color de imagen; Algoritmos de clasificación; Reconstrucción de imagen	Si
Técnica de evaluación de calidad no destructiva para Phyllanthus Emblica (Gooseberry) procesada que utiliza procesamiento de imágenes	2013	Histogramas; Detección de borde de imagen; Análisis de color de imagen; Forma; Detectores; Extracción de características; Algoritmos de clasificación	Si
Segmentación de la fruta del huerto utilizando el aprendizaje multispectral.	2013	Segmentación de imágenes; Extracción de características; Análisis de color de imágenes; Capacitación; Precisión; Robots; Forma	Si
Procesamiento de imágenes para agricultura inteligente: detección de enfermedades y clasificación de frutas.	2013	Enfermedades; Análisis de color de la imagen; Bases de datos; Extracción de características; Morfología; Redes neuronales artificiales; Vectores	Si
Sistema de clasificación de cítricos en tiempo real basado en FPGA	2014	Análisis del color de la imagen; Arquitectura de la computadora; Hardware; Arreglos de puertas programables en campo; Itrio; Visión por computadora; Ecuaciones	Si
Sistema automatizado para clasificar los aguacates Hass según las técnicas de procesamiento de imágenes.	2014	Análisis del color de la imagen; Comunicación inalámbrica; Algoritmos de clasificación; Filtros Wiener; Diseño y análisis de algoritmos; Exactitud	Si
Un sistema de clasificación de madurez de tomate rentable que utiliza procesamiento de imágenes para agricultores	2014	Análisis de color de imágenes; Cámaras; Precisión; Diseño y análisis de algoritmos; Iluminación; Segmentación de imágenes	Si
Un método de segmentación basado en reglas para imágenes de frutas bajo iluminación natural.	2014	Segmentación de imágenes; Análisis de color de imágenes; Segmentación de objetos; Algoritmos de agrupamiento; Algoritmos de procesamiento de señales; Iluminación; Silicio	Si
Clasificación automática de fruta utilizando algoritmo de bosque aleatorio	2014	Extracción de características; Forma; Análisis de color de la imagen; Exactitud; Radio frecuencia; Capacitación; Máquinas de vectores de soporte	Si
Región no saludable de detección de hojas de cítricos mediante técnicas de procesamiento de imágenes	2014	Análisis de color de imágenes; Enfermedades; Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Mejora de imágenes; Algoritmos de clasificación	Si

Evaluando la frescura de los productos utilizando el aprendizaje por transferencia.	2015	Capacitación; Máquinas de vectores de soporte; Datos de capacitación; Estándares; Análisis de color de imagen; Correlación; Extracción de características	Si
Clasificación automática de aceitunas para la producción de aceite mediante visión artificial.	2015	Suelo; Producción; Histogramas; Visión por ordenador; Análisis de color de imagen; Cámaras; Análisis de componentes principales	Si
Clasificación automática basada en visión artificial de tomates cherry.	2015	Extracción de características; Análisis de color de imagen; Forma; Máquinas de vectores de soporte; Clasificación; Algoritmos de clasificación; Color	Si
Sistema automático de clasificación y clasificación de frutas usando la visión por computadora: una revisión	2015	Análisis de color de la imagen; Exactitud; Extracción de características; Forma; Visión por computadora; Agricultura	Si
Un método novedoso para personas con discapacidad visual mediante el reconocimiento de objetos.	2015	Análisis de color de la imagen; Reconocimiento de la imagen; Voz; Reconocimiento de la voz; Índices; Cabeza; Yttrium	Si
Histograma basado en la identificación del patrón de color de la fruta multiclase mediante la selección de características	2015	Análisis de color de imágenes; Histogramas; Extracción de características; Reconocimiento de objetos; Algoritmos de filtrado; Cuantización (señal); Escala de grises	Si
Procesamiento de imágenes para la detección de la etapa de maduración del mango: método RGB y HSV	2015	Pruebas; análisis de color de la imagen.	Si
Diagnóstico de enfermedades de la planta de granada mediante red neuronal.	2015	Enfermedades; Extracción de características; Algoritmos de clasificación; Microorganismos; Segmentación de imágenes; Capacitación; Algoritmos de agrupamiento	Si
Detección de frutas basada en la textura a través de imágenes utilizando los patrones suaves en la fruta.	2016	Agricultura; Tuberías; Análisis de color de imagen; Iluminación; Resolución de imagen; Detectores; Forma	Si
Un marco para medir el nivel de infección en las vainas de cacao.	2016	Análisis del color de la imagen; Segmentación de la imagen; Máquinas de vectores de soporte; Enfermedades; Algoritmos de agrupamiento; Capacitación; Regiones	Si
Un estudio comparativo de los métodos de extracción de características en la clasificación de defectos de mangos utilizando una red neuronal	2016	Extracción de características; Segmentación de imágenes; Análisis de color de imágenes; Color; Algoritmos de clasificación; Piel; Minería de datos	Si
Identificación automática de defectos y sistema de clasificación para manzanas 'Jonagold'	2016	Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Análisis de color de imágenes; Capacitación; Algoritmos de agrupamiento; Histogramas	Si
Modelo difuso optimizado de enjambre de partículas para la clasificación de la madurez del banano	2017	Análisis de color de la imagen; Extracción de características; Color; Sensores; Máquinas de vectores de soporte; Lógica difusa	Si
Identificación y conteo de manzanas maduras basadas en la red neuronal de BP feed forward	2017	Análisis del color de la imagen; Extracción de características; Redes neuronales biológicas; Algoritmos de procesamiento de señales; Agricultura; Algoritmos de clasificación	Si
Reconocimiento automático de frutas a partir de imágenes naturales con características de color y textura.	2017	Análisis de color de imágenes; Extracción de características; Segmentación de imágenes; Máquinas de vectores de soporte; Circuitos integrados; Capacitación; Diseño y análisis de algoritmos	Si
Detección automática de moretones en tiempo real en frutas (Apple) usando una cámara térmica	2017	Segmentación de imágenes; Extracción de características; Algoritmos de agrupamiento; Diseño y análisis de algoritmos; Algoritmos de clasificación; Análisis de color de imagen; Estándares	Si
Recuperación de imágenes basada en contenido para el reconocimiento de frutas de múltiples objetos utilizando k-means y k-vecino más cercano	2017	Análisis de color de imágenes; Extracción de características; Forma; Histogramas; Bases de datos; Reconocimiento de imágenes; Algoritmos de agrupamiento	Si
Identificación del tamaño y madurez de la fruta a través de imágenes de frutas utilizando OpenCV-Python y Rasberry Pi	2017	Análisis de color de imágenes; Histogramas; Índices; Visión por computadora; Medición de tamaño; Algoritmos de agrupamiento	Si
Clasificación de imágenes basada en la región utilizando técnicas de transformación de cuencas hidrográficas.	2017	Segmentación de imágenes; Transformaciones; Clasificación de imágenes; Extracción de características; Detección de bordes de imágenes; Análisis de color de imágenes; Recuperación de información	Si
Reconocimiento de la condición madura, inmadura y escalada de los cítricos anaranjados según la clasificación del árbol de decisión	2018	Árboles de decisión; Extracción de características; Análisis de color de imagen; Redes neuronales artificiales; Segmentación de imágenes; Industrias	Si

Clasificación basada en el procesamiento de imágenes de pardeamiento enzimático en manzanas picadas	2018	Segmentación de imágenes; Extracción de características; Análisis de color de imágenes; Dominio de ondulación; Algoritmos de agrupamiento; Cámaras	Si
Sistema de reconocimiento de especies de durian basado en representaciones de formas globales y vecinos K-Nearest	2018	Análisis de color de imágenes; Extracción de características; Forma; Reconocimiento de imágenes; Bases de datos; Pruebas; Capacitación	Si
Detección de café (Coffea Arabica L.) eventos de floración secuencial basados en la segmentación de la imagen	2018	Segmentación de imágenes; Máquinas de vectores de soporte; Superficies selectivas de frecuencia; Capacitación; Fusión; Análisis de color de imágenes; Detección de eventos	Si
Método de clasificación de Apple basado en características de color y defecto	2018	Análisis de color de imágenes; Extracción de características; Máquinas de vectores de soporte; Detección de bordes de imágenes; Segmentación de imágenes; Algoritmos de clasificación; Visión artificial	Si
Clasificación de enfermedades y clasificación de naranja mediante aprendizaje automático y lógica difusa	2018	Enfermedades; Extracción de características; Análisis de color de imagen; Segmentación de imagen; Máquinas de vectores de soporte; Algoritmos de clasificación; Lógica difusa	Si
Clasificación de la calidad y madurez de los mangos cosechados según las técnicas de aprendizaje automático	2018	Análisis de color de la imagen; Forma; Máquinas de vectores de soporte; Algoritmos de clasificación; Extracción de características; Clasificación; Núcleo	Si
Visión de máquina en tiempo real de alta precisión para la medición de diámetros usando el algoritmo Simpson	2018	Calibración; Medición de tamaño; Cámaras; Análisis de color de imagen; Confiabilidad; Medición de área; Incertidumbre de medición	Si
Detección de Canarium Ovatum (Pili) maduro mediante el clasificador Adaboost y el análisis de color	2018	Análisis de color de la imagen; Extracción de características; Algoritmos de clasificación; Capacitación; Iluminación; Agricultura; Aprendizaje automático	Si
Técnica de detección de calidad mejorada para frutas que utilizan GLCM y MultiClass SVM	2018	Extracción de características; Análisis de color de imagen; Cámaras; Segmentación de imagen; Matlab; Hardware	Si
Conteo robusto de frutas: combinación de aprendizaje profundo, seguimiento y estructura desde el movimiento	2018	Segmentación de imágenes; Seguimiento; Pantallas tridimensionales; Tuberías; Secuencias de imágenes; Aprendizaje profundo; Cámaras	Si
Conteo de manzanas utilizando redes neuronales convolucionales	2018	Análisis del color de la imagen; Estimación del rendimiento; Agricultura; Segmentación de la imagen; Algoritmos de agrupamiento; Análisis de tareas; Vegetación	Si
Un algoritmo modificado de detección de borde de Canny para detección y clasificación de frutas	2018	Detección de bordes de imagen; Análisis de color de imagen; Extracción de características; Algoritmos de clasificación; Forma; Clasificación	Si
Una clasificación automatizada de la calidad del tomate utilizando una máquina de vectores de soporte basada en agrupación	2018	Análisis de color de imagen; Máquinas de vectores de soporte; Extracción de características; Visión artificial; Cámaras; Algoritmos de clasificación	Si
Clasificación de la fruta de grosella espinosa del cabo según su nivel de madurez utilizando técnicas de aprendizaje automático y diferentes espacios de color	2019	Análisis de color de imágenes; Electrónica aeroespacial; Máquinas de vectores de soporte; Visualización; Segmentación de imágenes; Inspección; Instrumentos	Si
Un método optimizado para la segmentación y clasificación de las enfermedades de la manzana basadas en una fuerte correlación y en la selección de características basadas en algoritmos genéticos	2019	Enfermedades; Extracción de características; Análisis de color de imagen; Segmentación de imagen; Algoritmos genéticos; Lesiones; Máquinas de vectores de soporte	Si
Recuento automático y tamaño individual y estimación en masa de olivos a través de técnicas de visión artificial.	2019	Análisis de imágenes; Modelado computacional; Extracción de características; Estimación; Visión por computadora; Industrias; Segmentación de imágenes	Si
Clasificación del tomate según la madurez organoléptica (coloración) mediante algoritmos de aprendizaje automático K-NN, MLP y K-Means Clustering	2019	Algoritmos de clasificación; Análisis de color de imagen; Algoritmos de agrupamiento; Histogramas; Bases de datos; Estándares; Iluminación	Si

PRE 3. ¿Qué modelos de inteligencia artificial existen para realizar el procedimiento de clasificación de frutas

La clasificación de frutas es un tema ampliamente explorado teniendo al procesamiento de imágenes RGB como el proceso más estudiado para explotar características significativas de la fruta, como el color, la forma, la textura y el tamaño de los sistemas convencionales de visión artificial. El análisis de calidad, la identificación de enfermedades y el análisis de daños se encuentran entre las principales aplicaciones de la clasificación de frutas basada en la visión artificial. Las Investigaciones más relevantes expuestas por el filtro final demuestran que se han utilizado una variedad de modelos de aprendizaje automático tales como, k-NN, SVM, árboles de decisión, algoritmos fuzzy logic, RNA y sus variantes para este propósito. A continuación se muestra la tendencia porcentual en la Figura 3.3 la cual expone la eficiencia de los modelos encontrados en los artículos antes filtrados.

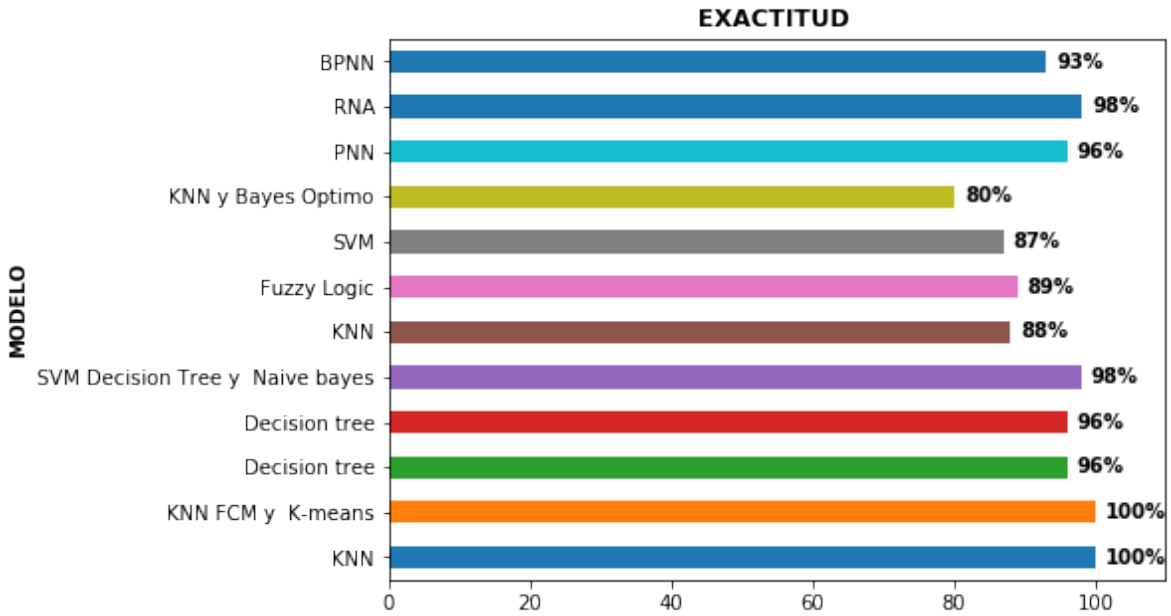

Figura 3.3: Selección de los algoritmos de clasificación. Fuente: Elaboración propia

Tabla 3.3: Análisis de rendimiento de los algoritmos de clasificación. Fuente: Elaboración propia

Año	Fruta	Tamaño DataSet	Característica	Clasificador	Exactitud	Ref.
2018	Fresa	2969	Color	KNN, FCM, K-means	100%	[39]
2018	Papaya	114	Color	Decision tree	95,98%	[79]
2018	Mango	100	Color	Decision tree	96%	[80]
2018	Papaya	129	Color	SVM, Decision Tree, Naive bayes	90%	[81]
2017	Berenjena	50	Color	KNN	88%	[82]
2017	Mango	250	Color	Fuzzy Logic	89%	[83]
2016	Mango	200	Color	SVM	87%	[84]
2013	Naranja	200	Textura, Forma e Intensidad	PNN	96%	[20]
2013	Manzana	150	Color	RNA	98,10%	[55]
2012	Manzana, Chikoo, Naranja, Mango y Limón Dulce	5000	Color, Textura	BPNN	93%	[15]

PRE 4. ¿En que convergen las conclusiones relacionadas a la clasificación de frutas?

En relación a cada conclusión mostrada en los artículos las cuales se muestran en la matriz de resumen de la revisión bibliográfica se puede evidenciar que la mayoría de las propuestas relacionadas al proceso de clasificación no destructiva de frutas utilizando aprendizaje convergen en lo siguiente:

1. El problema base de donde parten las propuestas es que se sigue clasificando las frutas bajo la perspectiva del ojo experto de un ser humano y esto evidencia ciertos problemas como la excesiva concentración, debe relacionarse con muchas características de la fruta lo cual implica que no se pueda lograr un estar en todos los implicados, manipulación de

la fruta lo cual podría conllevar a una contaminación de la misma, entre otros. Afectando de forma directa el proceso de clasificación.

2. El tamaño de las bases de datos están ligados estrictamente al modelo con el cual se esté trabajando ya sea supervisado o no supervisado, a la o las características con las cuales se esté entrenando los modelos y fundamental los recursos con los que se cuente para ejecutar dichos modelos.

3. El preprocesamiento de los datos es el proceso con mayor influencia en la clasificación de frutas ya que estandarizar los datos genera un impacto directo en la eficiencia del modelo.

4. La característica de color es la más significativa en términos descriptivos de una fruta para dar su valoración final en relación al estado de madurez.

5. Los modelos de color CIE L*a*b* y HSI son los que se usa comúnmente para realizar la clasificación ya que está relacionado con la percepción humana.

6. Entre el sinnúmero de técnicas de aprendizaje automático, la máquina de vectores de soporte (SVM, por sus siglas en inglés) dio la mayor precisión, pero ANFIS (sistema de interferencia borroso neuro adaptativo) mostró el mejor resultado de estas técnicas. Además, los algoritmos Fuzzy experimentan resultados con una tasa de precisión más baja, pero es fácil de implementar.

4. CONCLUSIONES

Basado en la literatura, en este documento se presenta una revisión actualizada de la clasificación de frutas y de los procesos que se deben cumplir para llevar a cabo este procedimiento. Cabe mencionar que, se han identificado retos significativos que deben superarse en términos de dispositivos de adquisición de datos, representación de características y algoritmos de clasificación. Se debe aclarar que, la clasificación de frutas es un tema ampliamente explorado teniendo al procesamiento de imágenes RGB como el proceso más estudiado para explotar características significativas de la fruta, como el color, la forma, la textura y el tamaño de los sistemas convencionales de visión artificial. Además, el análisis de calidad, la identificación de enfermedades y el análisis de daños se encuentran entre las principales aplicaciones de la clasificación de frutas. Investigaciones recientes han utilizado una variedad de modelos de aprendizaje automático entre los más significativos se encuentran k-vecinos más cercanos (k-NN), SVM, Árboles de decisión y Redes neuronales (RNA) y sus variantes para llevar a cabo este este propósito generando resultados extraordinarios siempre enmarcados en un ámbito netamente experimental.

4.1 Limitaciones

- Los sensores utilizados para la adquisición de datos en la industria alimentaria se encuentran limitados debido a limitaciones sustanciales en varias aplicaciones.

- El uso de múltiples sensores en la misma aplicación relacionada a la clasificación no destructiva de frutas es diferente a la naturaleza de los datos producidos por una persona considerada experta.

- Los descriptores de características desarrollados y utilizados en el estado actual de la técnica de clasificación no destructiva de frutas son insuficientes para generar una semejanza estándar como la que logra el experto.

MATRIZ DE RESUMEN DE LA REVISIÓN BIBLIOGRAFICA DE LOS ARTICULOS DE INTERES

N°	Año	Tema que aborda	Problema que enfrentó	¿Que se hizo?	hizo? (El método que uso y las técnicas que uso)	¿Qué resultados obtuvo? (Hallazgos concretos)	Conclusiones relevantes	Fruta	Característica	Modelo de color	Algoritmos	Adquisición de datos	pre procesamiento
1	2010	Clasificación de madurez de color de la fruta Carambola usando Cr(croma) como característica	La inspección de calidad para la exportación de la fruta Carambola todavía se realiza manualmente por el trabajo humano hasta hoy	Se desarrolla un sistema en tiempo real para la inspección de madurez del color de la fruta de la fruta Carambola	Se plantea una derivación de un método propuesto el cual utiliza el modelo de color HSI, entonces se plantea la conversión al modelo de color YCbCr para que no se tenga que trabajar con colores aditivos o sustractivos y de modo de ahorrarse tiempo calculando expresiones matemáticas. Además se utiliza el componente croma Cb y Cr los cuales representan la madurez el fruto, cabe resaltar que de los componentes antes mencionados Cr es siempre seis veces mayor en comparación con Cb. Por lo tanto, el componente Cb se puede quitar de la ecuación, ya que da muy menos efecto a la ecuación comparar con Cr (justificación de porque utilizan solo el componente croma Cr). Por otra parte se utiliza un clasificador lineal expresado en dos clases. Para probar los algoritmos propuestos, se utilizaron 600 muestras carambola; 300 para el entrenamiento y la otra 300 son para probar el rendimiento de los algoritmos. Cada una de	En este nuevo algoritmo modificado, presenta un sistema más rápido que el anterior ya que el proceso de clasificación de madurez de la fruta debido a que funciona sin ninguna operación matemática involucrada en el proceso de extracción de características. Este proceso es posible ya que la información de color se puede obtener directamente del componente Cb y Cr, que no es el caso en el espacio de color RGB. Según los resultados del experimento, la precisión de la clasificación para el algoritmo modificado es del 96%.	El algoritmo diseñado para el procesamiento de imágenes en color es popular entre los investigadores de hoy en día. Esta nueva característica para el sistema de clasificación de color proporciona una precisión buena precisión. Además este algoritmo es fácil para implementar en el sistema en tiempo real porque en la industria el dispositivo del sistema de visión para adquirir la imagen, o Los datos de vídeo utilizan el espacio de color YCbCr. Al mejorar la algoritmo anterior, el sistema también será más rápido en tiempo real porque no hay necesidad de convertir el color YCbCr sistema de adquisición de datos de espacio a espacio de color RGB para procesamiento	Carambola	Color	YCbCr	Adaptación propia.	cámara normal compuesta con la salida YCbCr	segmentación (proceso de segmentación, Cb se utiliza para discriminar el fondo de la imagen)

					las 300 muestras es inclusivo de 50 muestras por índice de madurez								
2	2011	Clasificación de frutas basadas en color utilizando GPU	Hoy en día la distinción entre las diferentes cualidades de las manzanas se basa en medidas empíricas propuestas por expertos	En este trabajo se presenta una solución que implementa un método de reconocimiento del color de las frutas a partir del entrenamiento previo del sistema, junto con un mecanismo sincronización que mejora la velocidad de procesamiento mediante el uso de GPU	Se utilizó el procesamiento de imágenes para ello se realizó la captura de video de forma continua utilizando una cámara comercial, a una velocidad de 30 fps. Y una resolución de imagen de 720*480 píxeles. La cámara se encuentra conectada a una PC estándar mediante una conexión de video IEEE1384 en un ambiente controlando la reflectancia. La adquisición de la imagen es debe estar sincronizada con el cambio de posición y rotación del fruto en la línea, de manera de asegurar que las imágenes obtenidas desde el video cubra toda la superficie del fruto (5 imágenes). Estas imágenes son luego alineadas para recrear la "piel" o cáscara del fruto; Luego se realizó el procesamiento la imagen para extraer el fondo el cual corresponde a los rodillos para ello se realizó filtros de umbralado en el espacio de colores HSL (H = Cromaticidad, S = Saturación, L = Iluminación), el cual facilita la discriminación de la	Dados los tiempos de cálculo requeridos por la GPU, se observa que es posible ejecutar el algoritmo muestreando hasta 12 líneas de forma simultánea (equivalente a 4 vídeos) permitiendo mantener una mayor velocidad de captura, de aproximadamente 69 fps, sobrepasando la cantidad de 20 fps que necesitaría el sistema para que funcione en tiempo real sin perder detecciones. De los 3 lotes mencionados el resultado es (72.2%, 33.3%, 83.3%) respectivametes en cuanto a los verdaderos positivos	Se presentó un sistema de clasificación de frutos en una línea de transporte, el cual utiliza técnicas novedosas para la determinación de la calidad del fruto, y realiza el procesamiento mediante GPU. Este sistema permite analizar múltiples líneas en un sólo equipo, lo que implica un menor costo de adquisición por módulo, y simplifica la tarea sincronización del software con la máquina de transporte. Por otro lado, se reduce la necesidad de espacio físico, al requerirse una única PC. Actualmente se está integrando al sistema de clasificación un módulo de generación de videos de forma sintética, que acelera el proceso de prueba de los algoritmos y permite aumentar los casos de análisis.	Manzana	**Color**	**HSL**	Propuesta propia apoyada en GPU	Cámara de video	-

					croma o color del fruto. Finalmente se realiza la clasificación para ello se entra el sistema propuesto bajo los criterios del experto aplicando un método de aprendizaje. En resumen el método propuesto es (CAPTURA-SEGMENTA-TRACKEA-COMPAGINA Y CLASIFICA). Se utilizó 3 lotes de 72 frutos clasificados por un experto y se untilza una matriz de confusión para evaluar el modelo								
3	2011	Detección de defectos en manzanas utilizando algoritmo EM basado en histograma estadístico	La segmentación de una imagen en sus componentes juega un papel importante en la mayoría de las aplicaciones de procesamiento de imágenes.	Se estudia una aplicación importante del procesamiento de imágenes para determinar la calidad de la manzana y se propone un algoritmo automático para determinar los defectos del color de la piel de las manzanas.	Primero, esta imagen se convierte de RGB a espacio de color L * a * b *. A continuación, la forma de la fruta se extrae mediante un algoritmo CM. Finalmente, la imagen se ha segmentado usando un algoritmo SHEM.	Los resultados muestran que tanto EM como SHEM pasan las mismas iteraciones para realizar el proceso de segmentación y obtener los mismos resultados. Sin embargo, el algoritmo SHEM propuesto consume menos tiempo que el algoritmo EM estándar. La precisión del algoritmo propuesto en las imágenes adquiridas es de 91.72% y 94.86% para píxeles sanos y defectuosos.		Manzana	Color	RGB, L*a*b*	CM Y SHEM		segmentación

4	2011	Detección de defectos en manzanas mediante el uso de histograma estadístico basado en un algoritmo difuso de C-means	La segmentación de imágenes es uno de los procesos importantes y complicados entre el procesamiento de imágenes y los algoritmos de visión por computadora.	Primeramente se adquiere las imágenes las cuales están en modelo aditivo RGB esta se convierte al modelo de color L*a*b*, luego se extrae la forma utilizando ACM (Asociación for Computing Machinery), luego se realiza la segmentación utilizando el algoritmo propuesto SHFCM el cual es mejor que el algoritmo estándar de FCM.	(1)Las imágenes fueron tomadas por una cámara de tipo matriz de 3 CCD (DSC-T900, Sony) de una vista. La cámara se colocó a unos 400 mm de la parte superior de la fruta y fue capaz de tomar 640 × 480 píxeles Imágenes, con una resolución de color de 3 × 8 bits por píxel. Las cámaras de iluminación fue diseñada para proporcionar Iluminación difusa sobre las superficies frutales, con el objetivo de Evitar los reflejos y reflejos de luz. (2) Extracción de la forma de manzana utilizando algoritmo ACM. (3) Calcular el histograma estadístico basado en medios en el algoritmo difuso C-means	La evolución de la propuesta se realiza utilizando una matriz de confusión y se obtuvo, Precisión de la Algoritmo para detección de píxeles sanos y defectuosos. Las unidades son 91% y 96%, respectivamente. En este caso, el componente a *, se utiliza como espacio característico. Finalmente, las imágenes segmentadas de la fruta. Por el algoritmo SHFCM propuesto se muestran en cuarto columna. Visualmente, se puede observar que el color seleccionado. El espacio L * a * b * es el mejor vector de características del espacio de color para Extracción de defectos. También se menciona nuestra vasta Los resultados experimentales muestran que SHFCM consume menos Tiempo que el algoritmo estándar de FCM. Entonces, en este papel, Se propone un algoritmo con alta precisión y velocidad. Para la segmentación de las imágenes de manzana	En este trabajo se presenta un algoritmo automático para Determinar los defectos del color de la piel de las manzanas. El algoritmo consta de tres etapas: en primer lugar, la imagen era convertido de RGB a espacio de color L * a * b *. En segundo lugar, La forma de la fruta se extrajo utilizando el algoritmo ACM. Al final, en la tercera etapa, la imagen se segmenta usando Algoritmo SHFCM. Resultados experimentales sobre la manzana. Conjunto de datos indica que tanto FCM como SHFCM gastan lo mismo iteraciones para llevar a cabo el proceso de segmentación y Obtener los mismos resultados. Pero la propuesta de SHFCM El algoritmo consume menos tiempo que el FCM estándar. Algoritmo. La exactitud del algoritmo propuesto en las imágenes adquiridas fue de 91% y 96% para píxeles sanos y Los desertados, respectivamente.	**Manzana**	**Color**	**RGB, L*a*b***	**SHFCM Y FCM**	cámara de tipo matriz de 3 CCD (DSC-T900, Sony)	segmentación

5	2012	Un método basado en FCM para reconocer y extraer tomate maduro para el sistema robótico de cosecha	Es la clasificación de las frutas adecuadas ya que es considerado un proceso muy importante garantizar la correcta selección de los productos utilizando las técnicas de procesamiento de datos para la extracción de ruido	Se propone un método basado en FCM (Fuzzy C-Means) que se combina con la morfología matemática. parra ello hace uso del algoritmo de agrupación FCM el cual se emplea para separar el original imagen en el espacio de color CIE L * a * b *, y luego usando el El enfoque morfológico y el rasgo geométrico de la Imagen para extraer la zona de	Se obtiene las imágenes de tomate de un huerto seleccionado. La imagen que se obtiene utilizando un sensor de visión de imagen en color, para ello se utilizó el espacio de color CIE L * a * b * ya que el mismo expresa el color de una forma similar a la percepción de hoy o del ser humano. Luego, se realiza el procesamiento de la imagen utilizando la segmentación para el componente de la característica de color efectiva se realiza mediante el método de segmentación FCM. Después de eso, el componente con las características deseadas se puede obtener y transferir a una imagen binaria para su posterior procesamiento. Por último, El método de morfología matemática con característica geométrica se utiliza para extraer el componente conectado más grande como el resultado ideal, y para marcar el centro y el rectángulo encuadernado de la fruta reconocida.	Todos los experimentos se llevaron a cabo en Matlab. Sistema operativo 2009a y Windows 7 (4GRAM y CPU Intel de 2.67GHz) para probar el tiempo y la eficiencia del algoritmo de extracción. En el experimento, 20 imágenes de tomate son aleatorias. Elija la base de datos de imagen de formulario utilizada para probar 18 de ellos son Se extrae con éxito mientras que 2 de ellos fallan. A fin de que obtener el tiempo promedio, algunas imágenes de entrada se ajustan a 640 * 480, y en esta situación, el tiempo medio de ejecución de la propuesta El método es 8.23s. Comparando con la segmentación K-medias. Algoritmos bajo las mismas circunstancias, el propuesto algoritmo tiene menos consumo de tiempo, y tiene un poco Mejora en la partición preparatoria y adaptativa.	El método propuesto es efectivo para obtener un resultado de extracto ideal. Incluso en un contexto complejo todavía tiene un buen efecto obteniendo un consumo de tiempo aceptable. Cabe mencionar que por supuesto presenta algunos inconvenientes ya que necesita ser mejorado. Tales como, si la fruta madura. No es obvio, el área de destino final puede no ser un resultado ideal. Otra desventaja es el tiempo de cálculo. Aunque el computadora de alto rendimiento con buen hardware puede procesar rápidamente para reducir el tiempo de cálculo, todavía debería ser necesario Optimizado en algoritmo.	**Tomate**	**Color**	**L*a*b**	**Fuzzy C-Means**		segmentación

				fruta madura									
6	2012	Clasificador Multi Class Support Vector Machines para aplicación de visión artificial.	La clasificación de objetos es un campo importante y muy inconsistente generando preocupación en las aplicaciones de visión artificial teniendo la incógnita abierta ya que no se puede garantizar100% de efectividad.	Se desarrolló de un clasificador SVM multiclase que emplea el método de votación de una ganancia máxima de uno contra uno y el uso de la función de base radial (RBF) y los núcleos lineales. Los clasificadores desarrollados se han aplicado para la clasificación basada en el color de las frutas de	.Las imágenes de manzana se obtienen por separado. Y las imágenes se analizan mediante el procesamiento de imágenes. Los algoritmos y los datos de características resultantes se clasifican. Por separado en la moda fuera de línea. El clasificador SVM ha sido Desarrollado usando codificación explícita en MATLAB mientras que KNN y clasificadores Naïve Bayes se implementan utilizando Funciones incorporadas correspondientes de MATLAB. Dicho método consiste en los siguientes pasos: (1) Adquisición de imágenes se realizó empleando una Cámara a color Logitech HD Pro 1080p con iluminación adecuada condiciones, se extrajo una base de datos de 270 imágenes de las cuales 82 corresponden a la categoría Fuji, 113 a Cachemira y 72 a Shimla. Para cada categoría, el 40% de las imágenes han sido utilizadas para entrenar clasificador y el 60% restante de imágenes se han utilizado para pruebas el clasificad. (2) Extracción de	Los resultados indican que entre los clasificadores SVM, SVM El clasificador con kernel RBF da una mejor clasificación Rendimiento que el clasificador SVM con kernel lineal. Los El clasificador SVM con kernel RBF da un 100% de precisión clasificación. El mejor rendimiento del kernel RBF puede atribuirse a su idoneidad para clasificar conjuntos de datos no lineales Comparado con el núcleo lineal. Los valores relativamente altos de Los valores de clasificación obtenidos para todos los clasificadores pueden ser atribuidos al hecho de que las diferentes variedades de manzanas son claramente diferente en el color de la superficie. Comparación entre SVM con kernel RBF y otros clasificadores indica que el clasificador SVM de clases múltiples con kernel RBF supera a la Otros clasificadores convencionales de KNN y Naïve Bayes	Un clasificador SVM multi-clase con kernel RBF tiene implementado y demostrado ser mejor que lo convencional Clasificadores para la aplicación de clasificación de frutas de manzana	Manzana	**Color**	**RGB, HSI**	SVM, KNN y Naïve Bayes	Cámara a color Logitech HD Pro 1080p	Segmentación

				manzana en tres clases predefinidas y su rendimiento se compara con los clasificadores convencionales de K-Nearest Neighbor (KN) y Naïve Bayes	características.- Las imágenes de manzana son pre procesadas utilizando la mediana. Filtrado para la eliminación del ruido. Los datos rojo, verde, azul (RGB) de las imágenes en color se convierten en matiz, saturación e intensidad. (HSI) datos. Las regiones frutales en las imágenes están segmentadas por Umbral adecuado de los valores de matiz y el componente rojo. (3) Clasificador de clases múltiples SVM.- El clasificador SVM multi-clase está desarrollado para clasificar las manzanas en tres categorías a saber, Fuji, Cachemira, y las variedades shimla. Dos clasificadores SVM multi-clase tienen ha sido desarrollado empleando la votación de uno a uno y máximo de victorias método y utilizando kernel RBF y kernels lineales, respectivamente. Los datos de entrenamiento de las 3 categorías de manzanas son alimentados como entrada al clasificador SVM. El clasificador está entrenado para clasifica los datos en 3 clases distintas. El clasificador Analiza internamente cada par de categorías de conjuntos de datos y genera adecuadamente 3 hiperplanos, cada hiperplano dividiendo un par de categorías de conjunto de								

					datos. Después de entrenar al clasificador, su El rendimiento ha sido validado mediante la alimentación seleccionada al azar datos de entrenamiento. El clasificador se prueba alimentando la prueba conjuntos de datos de las 3 categorías de manzanas.								
7	2012	Clasificación de mangos por características de objeto y modelado de contorno.	La clasificación de objetos desempeña un papel vital en las aplicaciones de visión artificial, como la toma de decisiones en aplicaciones industriales, el análisis de imágenes satelitales, la interpretación de imágenes médicas, etc. La clasificación inter e intra	Se propone una solución basada en el procesamiento de imágenes para la clasificación intra de las frutas, especialmente los mangos, en función de las características de la forma y la región que son	Los objetos están segmentados de la base de datos recopilada. Se extraen imágenes y características. Se utilizan para entrenar bayes. Clasificador que funciona en la probabilidad y probabilidad de el objeto. En este trabajo propuesto, mayor probabilidad es predicha con las características primarias, llamado Contorno del objeto Modelo. La traducción existente, la rotación y la escala invariante. Características basadas en región y límite, nombradas como secundarias Las características se introducen en la fase de entrenamiento para estimar la probabilidad. Parámetros Mientras que la imagen de consulta es dada a	Las imágenes utilizadas para la experimentación se capturan con 8.1. mega píxel, Samsung ES10. Cada imagen tiene la resolución de 2304 x 3072, 8 bits de profundidad, con formato jpeg. La base de datos consta de 20 imágenes para cada clase de mango. El marco propuesto está probado con individuos y grupos de Mangos presentes en una imagen. El resultado del clasificador es de 90.91% y la clasificación errónea es de 9.09%.	Este trabajo presentó un novedoso método de procesamiento de imágenes para clasifica los mangos indios a saber Alfonza, Totapuri y Rumani Basado en generar un modelo de contorno de objeto. El método tiene sido probado sobre una variedad de imágenes de muestra que contienen tres Variedades de mango y se encuentra para proporcionar el 90% de precisión.	Mango	**Color**	**HSV**	Bayes de Object Contour Model	capturan con 8.1. mega píxel, Samsung ES10. Cada imagen tiene la resolución de 2304 x 3072, 8 bits de profundidad, con formato jpeg.	Procesamiento de imágenes

			de frutas en agroindustrias es uno de los procesos repetidos y prolongados. Dentro de la clasificación de frutas como el mango, el banano se está logrando por expertos humanos que son competentes en el comercio. Debido al importante crecimiento en la agroindustria y la falta de expertos, se requiere una automatización de la clasificación intra de las frutas.	invariantes en la traducción y la rotación. Estas características, junto con el clasificador Bayes de Object Contour Model, clasifican las variedades de mango.	la propuesta. Algoritmo, la probabilidad y la información a priori se obtienen. Para estimar el tipo de variedad de mango. El método consiste en: (1) Entrada de una imagen (2) Segmentación (método Otsu) (3) Extracción de características y finalmente se cuenta con datos para el entrenamiento y la clasificación.								

8	2012	Clasificación de objetos sólidos con formas definidas utilizando visión estereoscópica y un brazo robótico	Clasificación manual de los productos agrícolas.	Este proyecto implementa un módulo didáctico, que utiliza la visión estereoscópica para la estimación de la profundidad. El sistema identifica las coordenadas XYZ donde se ubican los objetos sólidos con formas definidas, y luego se utiliza un brazo robótico para manipular y clasificar los objetos según su forma y color. Algoritmos computacionales se	El hardware implementado incluye: un robot comercial. brazo, un par de cámaras con características similares, y un soporte como Estructura para el sistema. A. brazo robótico La evidencia de la clasificación de los objetos es realizada por Un brazo robótico comercial antropomorfo con 5 grados de libertad, con juntas revueltas y una pinza como final. efector B. cámaras USB Para la implementación de la visión estereoscópica, una webcam. "Minoru 3D" que se muestra en la Fig. 2 se usa en este proyecto. La cámara web se utiliza como dos cámaras 2D para tomar fotografías. De la escena (izquierda y derecha).	Se realizaron pruebas, los resultados muestran un 2% de error en la reconstrucción de la escena y un 10% de error en la colocación del brazo robótico sobre la fruta identificada.	La transformación del modelo de color RGB al modelo HSI permitió que el filtro de color funcione con una sola variable (H) en lugar de trabajar con tres planos de color (R, G, B), lo que garantiza un método viable para el análisis de color. Para cuantificar el error de posicionamiento de los diferentes objetos en la escena, se realizaron varias mediciones en la ubicación y se compararon con las estimadas por los algoritmos de posicionamiento. Los resultados mostraron un 2% de error en la reconstrucción de la escena y un 10% de error en la colocación del brazo robótico sobre la fruta identificada. Calibración de la cámara: el proceso determina la Parámetros de la cámara. Este procedimiento debe ser Realiza cada vez que las cámaras son desplazadas de su posición actual. • Clasificación de objetos: obtiene las posiciones de cada uno. Objeto utilizando un proceso de visión estéreo. Realiza el Clasificación de objetos según forma y color:	Naranjas, Mandarinas, manzanas, limones y tomates	**Color**	**XYZ, RGB, HSI**	algoritmos computacionales fueron desarrollados en LabVIEW	webcam. "Minoru 3D"	Adquisición de imágenes. Calibración de la cámara. Rectificación de imágenes Emparejamiento Determinación del mapa de disparidad. Reconstrucción de escenas 3D.

				han desarrollado en LabVIEW ® para la adquisición y el control del brazo robótico de la imagen. MATLAB ® Se utilizó para resolver el problema de la visión estereoscópica. Además, una aplicación basada en una red neuronal artificial fue entrenada con características de color y textura para identificar limones, manzanas, naranjas, mandarina			Objeto de muestra, rectángulo o esfera 3D y color: Rojo, amarillo y verde. • Identificación de la fruta: La aplicación utiliza un artificial. Red neuronal para identificar 5 tipos de frutas: naranjas, Mandarinas, manzanas, limones y tomates						

				s y tomates.									
9	2013	Técnica de evaluación de calidad no destructiva para Phyllanthus Emblica (Gooseberry) procesada que utiliza procesamiento de imágenes	La clasificación de la fruta en algunas áreas todavía se hace a mano, lo cual es tedioso e inexacto. Por lo tanto, existe la necesidad de mejorar la eficiencia y la precisión de esta evaluación de la calidad de la fruta que puede satisfacer las demandas de los mercados internacionales. Las tecnologías de bajo costo y no destructivas, capaces de clasificar la	Propone un método de evaluación de calidad no destructivo para categorizar una phyllanthus emblica procesada (grosella) utilizando el procesamiento de imágenes por características de color y textura.	Extiende las piezas uniformemente sobre la bandeja para evitar superposición Toma la imagen de las piezas por Cámara (12.1megapixels). Análisis de imagen digital en ordenador. Mostrar número de piezas pequeñas, normales, grandes y Para la colorización retráctil, piezas normales. Repita los pasos 1 a 4 para 10 a 15 muestras	El resultado del método propuesto es aproximadamente un 90% de precisión evaluando 595 frutas	Este artículo da técnica no destructiva de los automatizados. Análisis de calidad de piezas de grosella utilizando imagen. Procesando. Estamos calculando eje menor, eje mayor, área, La excentricidad para la clasificación de la grosella procesada. piezas. También hemos producido el algoritmo de colorización. y por esto identificamos la parte marrón o infectada. Desde En el cálculo de parámetros diferenciamos el pequeño, el normal y el Grandes piezas de grosella. Para esta clasificación también podemos considerar los más Parámetro de precisión y aplicación de cualquier técnica como Nueral. Red para cualquier muestra.	grosella	**Color y textura**	**RGB**	Canny	Cámara (12.1megapixels)	Procesamiento de imágenes

			grosella procesada de acuerdo con sus propiedades, ayudarían a promover las industrias de exportación de grosella										
10	2013	Segmentación de la fruta del huerto utilizando el aprendizaje multispectral.	Los métodos de clasificación actuales utilizados en escenarios agrícolas tienden a usar características basadas en aplicaciones hechas a mano.	Se planteo un algoritmo el cual se aplica a un problema de segmentación de fruta para una misión de vigilancia agrícola robótica, con el objetivo de proporcionar una estimación de rendimiento con alta precisión y robustez contra la variación de la fruta.	A. Modelado de imágenes usando campos aleatorios condicionales B. Aprendizaje de características 1) aprendizaje de funciones no supervisadas: 2) Aprendizaje de características semi-supervisadas C. Aprendizaje de características a múltiples escalas 1) Aprendizaje no supervisado en múltiples escalas 2) Aprendizaje semi-supervisado multiescala D. Característica de aprendizaje y CRF	Los resultados experimentales con datos recolectados en una granja de almendras utilizando el procedimiento de segmentación con las características extraídas de datos multiespectrales (color e infrarrojo) se logra una precisión de clasificación global del 88%.	Este artículo presentó un enfoque para la segmentación de imágenes de múltiples clases aplicada a una aplicación de segmentación de fruta de almendra. El algoritmo propuesto fue capaz de realizar una segmentación de fruta multiclase, sin iluminación artificial, sin suposiciones previas sobre las propiedades de la fruta objetivo, y por lo tanto es capaz de segmentar la fruta con una gran variación de tamaño. El enfoque multiclase también fue entrenado para segmentar ramas y hojas. El enfoque de aprendizaje hace que el algoritmo sea más robusto contra variaciones tales como cambios en la iluminación. El algoritmo propuesto logra una precisión de segmentación de vanguardia. Si bien demostramos el rendimiento en el conjunto de datos de	**Almendras**	**Color**	**RGB**	**Árboles de decisión**	Plataformas robóticas utilizadas en el ensayo de vigilancia agrícola.	Procesamiento de imágenes

							almendras, el enfoque propuesto es general y se puede aplicar a otras aplicaciones.						
11	2013	Procesamiento de imágenes para agricultura inteligente: detección de enfermedades y clasificación de frutas.	La necesidad de cultivar efectivamente una planta y aumentar su rendimiento es muy importante. Para hacerlo, es importante controlar la planta durante su período de crecimiento, así como, en el momento de la cosecha	Se plantea una técnica de procesamiento de imágenes utilizando como una herramienta para controlar las enfermedades en las frutas durante el cultivo, desde la plantación hasta la cosecha.	Se utiliza el concepto de red neuronal artificial. Se han seleccionado tres enfermedades de la uva y dos de la manzana. El sistema utiliza dos bases de datos de imágenes, una para la capacitación de imágenes de enfermedades ya almacenadas y otra para la implementación de imágenes de consulta. El concepto de propagación hacia atrás se utiliza para ajustar el peso de la base de datos de entrenamiento. Las imágenes se clasifican y se asignan a sus respectivas categorías de enfermedades en función de tres vectores de características, a saber, color, Textura y morfología.	Apartar de la propuesta planteada se evidencia que la morfología genera un 90% de resultado correcto y es más que otros dos vectores de características.	Este artículo demuestra algoritmos efectivos para la propagación de enfermedades y el conteo de mangos. La implementación práctica de redes neuronales se ha realizado utilizando MATLAB.	**Uva y manzana**	**Color, textura y morfología**	**RGB**	**Red neuronal artificial**	Cámara digital	Procesamiento de imágenes
12	2014	Sistema de clasificación de cítricos en tiempo real basado en FPGA											

13	2014	Sistema automatizado para clasificar los aguacates Hass según las técnicas de procesamiento de imágenes.	La clasificación de aguacates realizada por el hombre lleva tiempo que podría ser utilizada por el personal de la granja para realizar otras actividades destinadas a lograr estándares de calidad más altos y eficiencia de producción. El precio del producto y el mercado objetivo dependen en gran medida de la etapa de clasificación	Proponen un sistema basado en el procesamiento de imágenes de las fotografías de aguacates para su clasificación después de que se hayan retirado del árbol. El algoritmo de clasificación se ejecuta en una computadora que recibe las imágenes de la fruta de forma inalámbrica desde una cámara, el resultado se transmite utilizando los paquetes IEEE	A. Evaluando la madurez de la Palta Hass B. Proceso de filtrado C. Segmentación y detección de bordes D. Clasificación del Aguacate	El porcentaje de coincidencia del algoritmo de procesamiento de imágenes para seleccionar los aguacates fue del 88% en comparación con el conjunto de pruebas clasificado por los agricultores expertos. La matriz de confusión mostró una precisión del 82.22% al clasificar los aguacates.	Para evaluar el algoritmo implementado, se debe utilizar el comando se analizó el estado de madurez de los aguacates para 90 frutos. Error la estimación también se realizó utilizando el "Bootstrapping". Técnica y validación cruzada. El sistema propuesto permitía detectar el estado del aguacate. Se verificó que el análisis de la agrupación de los medios K permite clasificar cada una de las regiones extraídas de la imagen original como el aguacate verde, maduro y muy maduro aguacate, aplicando el criterio de la distancia mínima, obteniendo una precisión en los resultados del 87,85%. Matriz de confusión los resultados mostraron una precisión del 82,22% al determinar la madurez de los aguacates a partir de imágenes RGB.	**Palta**	**Color, forma**	**RGB**	**KNN**	Cámara digital	Procesamiento de imágenes

				802.15.4 y los aguacates se colocan en los rieles de la banda transportadora de acuerdo con sus categorías.									
14	2014	Un sistema de clasificación de madurez de tomate rentable que utiliza procesamiento de imágenes para agricultores	La clasificación de madurez o, en otras palabras, la clasificación de la madurez de una fruta, en función de su color o textura, constituye un proceso muy importante que deben llevar a cabo los agricultores y la industria de procesamiento de alimentos en todo el mundo. Las técnicas actuales involucran principalmente la	En este artículo analizamos un sistema de clasificación de madurez rentable para una de las frutas más populares del mundo: el tomate. Se ha presentado una configuración novedosa que utiliza material económico y algoritmos de procesami	A. Conversión de color de RGB a YCbCr: B. Segmentación del tomate. C. Eliminación de ruido D. Clasificación de los tomates	Se logró una precisión general del 98% con respecto a la detección del grado de madurez y se obtuvo una velocidad de ejecución superior a 7,6 veces en comparación con otras dos metodologías populares.	Este artículo describe una metodología novedosa para realizar. Clasificación de tomates con un alto nivel de precisión y una configuración de bajo costo. Además, vale la pena mencionar, que el algoritmo utilizado es menos complicado y el procesador más amigable que los algoritmos existentes elaborados. Cabe mencionar que ha futurio el alcance, mejorando la configuración se puede utilizar para examinar los niveles de madurez para un mayor número de frutos y esto se puede lograr mediante el aumento del tamaño de la plataforma. El algoritmo también podría ser utilizado para probar la madurez. Niveles para otras frutas como	**tomate**	**Color y textura**	**L*a*b, RGB y YCbCr**	**Algoritmos de procesamiento de imágenes.**	La cámara utilizada para los experimentos tiene los siguientes presupuesto: • Resolución de lentes: 4 megapíxeles. • Resolución: 640x480 • Velocidad de captura: 30 fps • Características: Función de encendido automático del LED en caso de intensidad de luz circundante reducida.	Procesamiento de imágenes

			inspección manual, lo que conduce a una clasificación errónea, que a su vez causaría pérdidas económicas debido a que productos inferiores ingresan a la cadena del mercado. También puede ocurrir una pérdida de rendimiento durante el almacenamiento con este tipo de clasificación, ya que también daría como resultado predicciones de fecha de caducidad erróneas. Existen varias metodologías para automatizar este proceso, pero involucran configuraciones muy caras y procedimient	ento de imágenes para identificar las seis etapas importantes de la maduración del tomate. Todos los algoritmos fueron diseñados y desarrollados usando Simulink, una parte de MATLAB 2011b en una CPU de 2.5 GHz			manzanas, cítricos y mandarina. naranjas por una ligera modificación en los modelos de color elegidos o el rango. Además, con el fin de comprobar el color en todos los lados de la Fruta, un motor vibrador podría ser colocado debajo de la plataforma en Para rotar la fruta y examinar una superficie mayor. Esta A su vez aumentaría la precisión. Así, de esta manera, El prototipo explicado en este trabajo podría ser utilizado más universalmente para una amplia variedad de frutas en una forma rentable y de manera precisa por los agricultores tanto en desarrollo como naciones desarrolladas en todo el mundo.						

			os complicados que no son una solución viable, especialmente para los agricultores de una nación en desarrollo.										
15	2014	Un método de segmentación basado en reglas para imágenes de frutas bajo iluminación natural.	La segmentación de imágenes es un proceso que es significativamente importante para el sistema de visión artificial, como el sistema automático de clasificación de fruta. Este proceso separa una imagen en varias áreas para extraer el objeto de interés de su fondo. Sin embargo, la tarea de segmentación es difícil	Este documento desarrolló un método de segmentación basado en reglas que es capaz de segmentar imágenes naturales de manera correcta y precisa. Este método utiliza el algoritmo IF-THEN para segmentar las imágenes del objeto de interés.	Los resultados del análisis mostraron que el nuevo método es capaz de producir imágenes segmentadas con una alta tasa de precisión. Los cuatro métodos de segmentación se implementan en imágenes de frutas y su rendimiento se compara en base a evaluaciones visuales y cuantitativas	Los resultados del análisis mostraron que el nuevo método es capaz de producir imágenes segmentadas con una alta tasa de precisión. Los cuatro métodos de segmentación se implementan en imágenes de frutas y su rendimiento se compara en base a evaluaciones visuales y cuantitativas. Los resultados del análisis mostraron que el nuevo método es capaz de producir imágenes segmentadas con una alta tasa de precisión.	En conclusión, TsNKM ha segmentado exitosamente Todas las imágenes seleccionadas de forma automática y precisa independientemente de Del color de la superficie del objeto en ambiente natural. Los Integración de medios K adaptativos y mejoramiento de los umbrales. Los algoritmos permiten a TsNKM seleccionar inteligentemente Proceso apropiado para cada imagen. Aunque TsNKM tiene un gran potencial en Segmentando imágenes naturales, este método tiene varias limitaciones. Especialmente para imágenes de objetos de forma no circular con varios colores, Por lo	**Frutas**	**Color**	**L*a*b, RGB y YCbCr**	**Otsu, K-means y Fuzzy C-means**	Cámara digital	Procesamiento de imágenes

			para aislar las imágenes capturadas en entornos al aire libre. Esto se debe a la existencia de una iluminación no uniforme en la superficie del objeto. Técnicamente, diferentes iluminaciones conducen a diferentes intensidades en el color de la superficie del objeto. Esta condición conduce a imágenes segmentadas de baja calidad y, por lo tanto, reduce la precisión de la clasificación de objetos. La segmentación de la imagen se puede lograr utilizando varios métodos, como Otsu,	Los cuatro métodos de segmentación se implementan en imágenes de frutas y su rendimiento se compara en base a evaluaciones visuales y cuantitativas			tanto, una mejora en este método. Se debe hacer para aumentar la precisión de la segmentación						

			K-means y Fuzzy C-means. Sin embargo, estos tres métodos tradicionales tienen limitaciones para producir áreas segmentadas precisas debido a la existencia de iluminación en la superficie del objeto.										
16	2014	Clasificación automática de fruta utilizando algoritmo de bosque aleatorio	La clasificación de madurez o, en otras palabras, la clasificación de la madurez de una fruta, en función de su color o textura, constituye un proceso muy importante que deben llevar a cabo los agricultores y la industria de procesamiento de alimentos en todo el	Se presenta un enfoque de clasificación eficaz basado en el algoritmo de bosque aleatorio (RF). Tres frutas, es decir, se analizaron las manzanas, las fresas y las naranjas y se extrajeron varias característi	Se inicia con una etapa de pre procesamiento que utiliza el procesamiento de imágenes para preparar el conjunto de datos de imágenes de frutas para reducir su índice de color. Luego se extraen las características de la imagen del fruto. Finalmente, el proceso de clasificación de frutas se adopta utilizando bosques aleatorios (RF), que es un algoritmo de aprendizaje automático desarrollado recientemente. Se usó una cámara digital normal para adquirir las imágenes y todas las manipulaciones se realizaron en un entorno MATLAB.	Los resultados experimentales muestran que la exactitud de las similitudes en los archivos de grupos de formas. La menor precisión entre los tres grupos. Para naranja y grupo fresa, la precisión de altura se logra (100%) con Extracción de características SIFT y clasificador KNN. La altura según Lo que se logró en el segundo grupo es de 96,97% de manzana (con Clasificador RF), y para 78.89% naranja (con clasificador SVM). Clasificar tercer grupo logra 96.97% para manzana cuando se usa Con extracción de características SIFT. Mientras que la fresa de alta precisión es 92.31% cuando se usa SIFT como extracción de características y KNN como clasificador En general, el algoritmo basado en RF proporciona mejor Precisión en comparación con el otro aprendizaje de la máquina bien conocido Técnicas como los algoritmos K-NN y SVM.	Los experimentos se probaron y evaluaron utilizando una serie de experimentos con 178 imágenes de frutas. Muestra que el algoritmo basado en el bosque aleatorio (RF) proporciona una mejor precisión en comparación con las otras técnicas de aprendizaje automático bien conocidas, como los algoritmos de K-NN y de vector de soporte (SVM). Además, el sistema es capaz de reconocer automáticamente el nombre de la fruta con un alto grado de precisión.	**Manzana, Fresa y Naranja**	**Color, textura y Invariante de la Escala (SIFT)**	**RGB, HSI**	**Random forest, Knn**	Cámara digital	Procesamiento de imágenes

			mundo. Las técnicas actuales involucran principalmente la inspección manual, lo que conduce a una clasificación errónea, que a su vez causaría pérdidas económicas debido a que productos inferiores ingresan a la cadena del mercado.	cas según la forma de las frutas, las características del color y la Transformación de la Característica Invariante de la Escala (SIFT)									
17	2014	Región no saludable de detección de hojas de cítricos mediante técnicas de procesamiento de imágenes											
18	2015	Evaluando la frescura de los productos utilizando el aprendizaje por transferencia											

19	2015	Clasificación automática de aceitunas para la producción de aceite mediante visión artificial.	Uno de los parámetros más importantes en la producción de aceite de oliva es la correcta recepción y clasificación de los frutos de oliva en lotes antes de iniciar el proceso de extracción de aceite. Lo cual al día de hoy se utilizan costosos componentes industriales para realizar la clasificación y no se garantiza la selección de calidad conociendo estos inconvenientes.	Este trabajo propone un sistema de inspección automático basado en la visión por computadora para clasificar automáticamente diferentes lotes de aceitunas para la producción de aceite cuando comienza el proceso de molienda.	La clasificación se basa en la diferenciación, en línea, entre el suelo y el olivo del árbol. Para este propósito, las muestras de aceitunas se obtuvieron recolectando bayas directamente del árbol o del suelo. El vector de características de las muestras se ha obtenido sobre la base de los histogramas de imagen de oliva. Además, se han empleado diferentes algoritmos de procesamiento de imágenes y técnicas de clasificación lineal, como el análisis discriminante de Fisher.	Se crea la base de datos de referencia de imágenes de hojas cítricas y En esa base de datos se utilizan diferentes técnicas de clasificación. Aplicado como máquina de vectores de soporte (SVM) con radial kernel base y kernel polinomial y varios experimentales Se obtienen resultados. Los diferentes entrenamientos y pruebas. Las muestras se utilizan durante el entrenamiento y las pruebas. Utilizando la mención de clasificador en la tabla II y la precisión de la El sistema se basa en el parámetro de evaluación de desempeño. Es decir, tasa de aceptación falsa (FAR) es del 4%, tasa de reconocimiento falso (FRR) es del 3% y la tasa de aceptación real (GAR) es del 96% para el clasificador SVMRBF. La falsa tasa de aceptación (FAR) es del 5%, la tasa de reconocimiento falso (FRR) es del 6% y la verdadera la tasa de aceptación (GAR) es del 95% para el clasificador SVMPOLY.	Este artículo presenta una serie de procesado de imágenes. Técnicas para extraer parte enferma de la hoja. SF-CES proporciona Mejor realce de la imagen en color, Lab y color Ycbcr. El espacio admite la agrupación K-mean para la extracción de partes de la enfermedad A través de los medios de agrupaciones. Entonces la característica de textura GLCM y las características de texturas de color se extraen para más propósito de la clasificación. Finalmente, la clasificación basada en SVM. Con este método, el uso de químicos dañinos en Las plantas puede ser reducidas y por lo tanto asegurar un sano. Ambiente. Debemos hacer más investigación sobre la prueba Equipos, procesamiento de imágenes y método de análisis para Lograr una mejor precisión de detección con diferentes plantas. especies	**Aceituna**	**Color**	**YCbCr, L*a*b***	**SVM**	Cámara digital	Procesamiento de imágenes

20	2015	Clasificación automática basada en visión artificial de tomates cherry.	Mencionan que la clasificación automatizada del tomate cherry se sigue llevando a cabo gracias a selección manual, la cual evidencia problemas que impactan de forma directa en el proceso de clasificación.	Se propuso un método para realizar la clasificación automática y no destructiva de los tomates cherry en función de la madurez y la calidad.	Este algoritmo comprende dos fases de calificación. La primera fase clasifica los tomates en términos de madurez y la segunda fase los tomates madurados en términos de calidad. Utilizando el concepto de cambio en color externo durante diferentes etapas de madurez, se ha propuesto un algoritmo de estimación de madurez basado en color. Y para clasificar el tomate en la segunda fase, las características de textura, color y forma correlacionadas con las características externas e internas se extraen de la superficie del tomate. También se ha propuesto extraer la superficie del tomate solo del fondo y dejar una nueva segmentación basada en el color basada en la distancia euclidiana. Luego, las características extraídas se asignan al clasificador de máquinas de vectores de soporte basado en el vecino más cercano K para clasificar las frutas maduradas en tres clases Clase I, II y III.	El resultado de la clasificación de la fase I para tres muestras de tomate. Para el primer tomate la proporción es mayor que 0.5, por lo que es tomate maduro mientras que para el segundo y tercero. La proporción de tomate es inferior a 0,5, por lo que estos dos son inmaduros. A estos, se aplica el algoritmo de verificación de madurez. La relación es mayor que 0.5 para ambos tomates, por lo que se aplica para la fase II. Clasificación. Para los que es una fruta podrida, el 3D el gráfico de GLCM y CLCM se muestra en (c) y (e). Lo mismo Parcela 3D para otra muestra de tomate que es de buena calidad. El tomate se muestra en la figura (d) y (f). Los resultados muestran que para buena calidad el GLCM y CLCM tiene un pequeño número de grandes picos en comparación con el tomate de mala calidad. Así que la superficie es Homogénea y uniforme para fruta de buena calidad. A partir de estos Matrices Se extraen características de textura, color y forma y dado a un clasificador SVM basado en KNN	En este trabajo se clasifica en dos fases en función de la madurez y Se ha desarrollado la calidad para los tomates cherry. Tenemos Recogió diferentes tomates en diferentes etapas de madurez con defectuosos y no defectuosos. La clasificación de la primera fase se basó en Color mientras que la segunda fase utiliza color, textura y forma. Características de los tomates. La clasificación basada en la calidad tiene realizado utilizando la clasificación SVM basada en KNN. Este clasificador combina el clasificador KNN y SVM para mejorar la Rendimiento en términos de precisión y tiempo computacional	**Tomate**	**Color, textura y forma**	**RGB**	**SVM, KNN**	Cámara digital	Procesamiento de imágenes

21	2015	Sistema automático de clasificación y clasificación de frutas usando la visión por computadora: una revisión	Al ser un artículo de revisión todas las imágenes convergen en que la clasificación automatizada es muy necesaria para garantizar un estándar en el procedimiento ya que al día de hoy se sigue llevando acabo por personas consideradas expertas.	La estructura del artículo es la siguiente: 1.- VISON POR COMPUTADORA A. Configuración de la visión por ordenador B. Características de color C. Características Morfológicas D. Características de la textura E. Aplicación de la visión por computador en el sistema de clasificación de la fruta 2.- MODELOS DE	-	Son netamente teóricos	En este trabajo, se revisan diferentes técnicas de clasificación basadas en el procesamiento de imágenes para el sistema de clasificación y clasificación de la fruta. Los sistemas de clasificación de frutas basados en visión artificial son capaces de reemplazar el trabajo de mano de obra para la inspección de la clasificación de frutas. Fuera de la característica morfológica, color y textura, la morfología dio la tasa de precisión más alta. En el modelo de color, el modelo de color HIS (Hue, Saturation, Intensity) se utiliza comúnmente para calificar porque está relacionado con la percepción humana. En técnicas de aprendizaje automático, SVM (Support Vector Machine) proporcionó la mayor precisión, pero ANFIS (Adaptive Neuro Fuzzy Interference System) mostró el mejor resultado de estas técnicas. Además, Fuzzy dio el resultado con la tasa de precisión más baja, pero es fácil de implementar.	**Frutas**	**Color, textura y forma**	-	-	Sensores digitales, acústicos y cámaras digitales	-

				CLASIFICACIÓN A. Lógica difusa B. Red Neural Artificial (ANN) C. Sistema de interferencia difusa neural adaptativa D. Máquina Vectorial de Soporte 3.- CONCLUSIONES									
22	2015	Un método novedoso para personas con discapacidad visual mediante el reconocimiento de objetos.											

23	2015	Histograma basado en la identificación del patrón de color de la fruta multiclase mediante la selección de características	El histograma de color se ha utilizado ampliamente en la extracción de características para representar la característica de color de un objeto en la imagen.	En este documento, identificamos qué características brindan una alta contribución en el rendimiento de la clasificación, ya que no todas las características están directamente relacionadas con la categoría de objeto.	En el caso del histograma de color de n bandejas, las características se referían al rango de intensidad de color del histograma de color. Por un lado, consideramos la clasificación de frutas, donde el espacio de características contiene varias propiedades de las intensidades de píxeles del canal RGB (rojo-verde-azul). Al seleccionar el subconjunto de características, consideramos el método de filtro de selección de características. En el método de filtro, reducimos sucesivamente el tamaño de los conjuntos de características e investigamos los cambios en los resultados de la clasificación. Específicamente, seguimos el enfoque de filtrado para la selección de características: Seleccionar las características en una sola pasada primero y luego aplicar un algoritmo de clasificación de forma independiente. Utilizamos la selección de características de chi cuadrado para determinar las características relevantes del histograma RGB. Además, utilizamos y evaluamos esas características relevantes en un sistema de clasificación, utilizando K-Nearest Neighbor (KNN) como clasificador.	En este documento, mostramos que al realizar técnicas de selección de características combinadas con KNN podríamos eliminar el valor de las intensidades no relevantes de los canales Rojo, Verde y Azul. Además, utilizamos el subconjunto relevante de características para identificar el rango de intensidades del canal RGB que se necesitaba para representar 32 subcategorías de imagen de fruta de manera eficiente. Utilizamos y evaluamos esas características relevantes en un sistema de clasificación, utilizando K-Nearest Neighbor (KNN) como clasificador.	En este documento, se propuso un método para crear un patrón de color para imágenes de frutas multiclase basadas en la selección de miradas de chi-cuadrado. El patrón de color consta de un rango de valores de intensidad seleccionado del canal R, G y B de imágenes RGB. Con el método de selección de características de c hi-square, podemos seleccionar el subconjunto de características que conduce a una alta precisión en la clasificación. Nuestros resultados experimentales demuestran claramente la efectividad de las funciones seleccionadas en términos de alto rendimiento de clasificación. Consideraremos extender nuestra idea al incorporar otros espacios de color que no sean RGB e incluir el peso adecuado durante la fusión del histograma. Se espera que esto logre un mejor desempeño. Aprovecharemos las combinaciones de componentes de color que se generalizan bien en las variaciones de iluminación en el contexto	**Manzana**	**Color**	**RGB**	**KNN**	Cámara digital	Procesamiento de imágenes

							del reconocimiento de frutas multiclase.						
24	2015	Procesamiento de imágenes para la detección de la etapa de maduración del mango: método RGB y HSV	El mango es una de las frutas comerciales producidas y consumidas en todo el mundo. Los mangos deben clasificarse según su etapa de maduración para uso comercial. Actualmente esta clasificación se realiza de forma manual, lo que no es preciso y es propenso a errores humanos. También suma la mano de obra y, por lo tanto, el costo y la	En este documento, hemos propuesto dos métodos para clasificar los mangos en función de los cambios en sus características visuales. Hemos considerado al mango Alfonso en nuestro trabajo, ya que es uno de los tipos de mango más famosos y comerciali	En el método RGB, la etapa de maduración se detecta en base al rojo, Los componentes verdes y azul de los píxeles de la imagen, mientras que en el método HSV, se analiza el mapa de valor de saturación de tono para la detección. Los algoritmos son propuestos e implementados utilizando MATLAB.	Los resultados se comparan con los resultados manuales y se encontró que son 90.4 y 84.2% de precisión en el caso de RGB y HSV respectivamente. También se demuestra que los métodos propuestos son insensibles a la cantidad de luz ambiental, siempre que la imagen se tome bajo la luz natural o bajo la luz blanca.	El análisis de las imágenes de mango Alfonso mostró claramente. Que hay cambios significativos en el color rojo, verde y azul. Componentes y valor-saturación-matiz con proceso de maduración. Los cambios relativos en los componentes se utilizan con éxito. Detectar la etapa de maduración del mango con una precisión de 90.4% y 84.2% con el uso de métodos RGB y HSV respectivamente. Tasa positiva falsa de 2. 57% en caso de RGB y Se observó 7.29% en caso de HSV. Tasa positiva verdadera de Se observó un 89,77% y un 86,74% en caso de RGB y HSV. Método respectivamente. Se encuentra que las tres ratios en RGB método a saber. Rojo a verde, rojo a azul y verde a azul Aumenta con el proceso	**Mango**	**Color**	**RGB, HSI**	**-**	Cámara digital	Procesamiento de imágenes

			eficacia generales de las industrias de procesamiento de mango.	zados. Pero los métodos propuestos pueden aplicarse a cualquier otra especie de mango que cambie de color con el proceso de maduración.			de maduración, pero con diferentes ritmos. También eso Se demuestra que el color azul tiene la menor ponderación en mango. En las imágenes, el color verde tiene la mayor ponderación en el mango no maduro. Y el color rojo tiene la mayor ponderación en el mango completamente maduro. Los También se estudió el efecto de la cantidad de luz ambiental y es encontró que el método RGB tiene mejor inmunidad sobre el HSV Método para la detección de la madurez. El trabajo aquí propuesto puede ser Solicitado la clasificación automática de mangos en. Industrias de transformación correspondientes. Los métodos propuestos No se pueden aplicar a los mangos que no cambian de color. Características con proceso de maduración. Otras características como la textura pueden ser utilizadas en algunos tipos de mangos. Se puede ampliar el trabajo. Para otras frutas, hortalizas, etc. para su clasificación y						

							calidad. propósito de control						
25	2015	Diagnóstico de enfermedades de la planta de granada mediante red neuronal.	La granada es una fruta que crece con un rendimiento muy alto en muchos estados de la India y una de las mayores ganancias que obtiene la fruta en el mercado. Pero debido a diversas condiciones, las plantas están infectadas por diversas enfermedades que destruyen todo el cultivo y dejan un rendimiento de producto muy inferior.	Por lo tanto, el trabajo propone un procesamiento de imágenes y métodos de redes neuronales para tratar los principales problemas de la fitopatología, es decir, la detección y clasificación de enfermedades. Tanto la fruta de la granada como las hojas se ven afectadas	Las imágenes en color se preprocesan y se someten a la segmentación de agrupamiento de k-means. Las características de la textura se extraen utilizando el método GLCM, Y dado a la red neuronal artificial.	La precisión global de este método es del 90%. Los resultados han demostrado ser precisos y satisfactorios en contraste con la calificación manual y se espera que aumenten considerablemente al establecerse en el mercado como uno de los procesos más eficientes.	De este trabajo propuesto, principalmente cuatro enfermedades de Las plantas de granada se clasifican y detectan utilizando Digital. Procesamiento de imágenes y técnicas de redes neuronales. Los Enfermedades como el tizón bacteriano, la mancha de la fruta, la pudrición de la fruta y la hoja. Las manchas se diagnostican utilizando la técnica anterior. El experimental Los resultados muestran que casi todas las muestras dan lo mejor. Discriminación entre las categorías mientras que solo una muestra.	**granada**	**Color - (GLCM)**	**-**	**k-means**	Cámara digital	Procesamiento de imágenes

				por diversas enfermedades causadas por hongos, bacterias y las condiciones climáticas. Estas enfermedades son como el tizón bacteriano, la mancha de la fruta, la pudrición de la fruta y la mancha de la hoja. El sistema usa algunas imágenes para entrenamiento, algunas para propósitos de prueba y así sucesivamente.									

26	2016	Detección de frutas basada en la textura a través de imágenes utilizando los patrones suaves en la fruta.											
27	2016	Un marco para medir el nivel de infección en las vainas de cacao.											
28	2016	Un estudio comparativo de los métodos de extracción de características en la clasificación de defectos de mangos utilizando una red neuronal	El "rey de las frutas" Mango (Mangifera indica L.) es la fruta más buscada para el consumo directo e indirecto en todo el mundo. Dado que tiene un valor de exportación muy alto, existe la necesidad de desarrollar una técnica que sea capaz de clasificar objetivamente los defectos de los mangos.	El rendimiento de cualquier clasificador depende de las características extraídas de la región de interés de la muestra.	En este documento, se realiza un estudio comparativo de los métodos de extracción de características para clasificar los defectos visibles de los mangos. El cultivar de mango "Alfonso" fue elegido para la experimentación. Se adquirieron 1766 imágenes en color con diferentes clases de calidad, se procesaron previamente y se extrajeron características texturales considerando una característica a la vez y también en combinación para cada imagen en color. Por lo tanto, obtuvimos 9 casos diferentes de combinación de diferentes características texturales. Además, las características más relevantes se seleccionaron de cada caso utilizando un algoritmo de	Las características texturales como estadísticas, LBP y bancos de filtros resultaron ser efectivas en el diseño de redes neuronales (NN) usando un clasificador de modelo lineal generalizado con una precisión de rendimiento de validación cruzada de 90.09%, 90.26% y 90.26% para funciones de activación lineal, logística y softmax respectivamente	En este trabajo, se ha considerado sólo las características de textura para clasificación de defectos como las características de textura no se acreditan a un valor de un solo píxel, sino más bien al conjunto de píxeles en la imagen y sus relaciones En nuestros experimentos, Caso 9 da lo mejor. Resultado en términos de tiempo computacional y rendimiento para Muestras de mangos. Y entre las diferentes salidas de activación. Funciones de NN, el rendimiento de NN con activación de softmax. La función logró la mayor tasa de precisión en casi todos los casos (Caso 1 al caso 9) pero	**Mango**	**Color y textura**	**RGB**	**RNA**	Cámara digital	Procesamiento de imágenes

					selección progresiva secuencial.		con un tiempo de computación ligeramente superior. NN Con función softmax se puede elegir para la mullticlass Clasificación de datos complejos. Activación lineal y logística. Las funciones eran simples y lograron buen desempeño en Tiempo razonable (1 a 4 segundos). Por lo tanto, fue posible lograr un rendimiento de clasificación razonable con solo selectivo Características texturales y excluyendo características geométricas y de contraste. Estos resultados indicaron que este estudio es un objetivo y un Herramienta confiable que puede extenderse a la calidad automática en línea Evaluación de mangos. El defecto externo propuesto. Técnica de clasificación combinada con evaluación interna de defectos. Utilizando cualquiera de las técnicas no destructivas disponibles, como rayos X, La TC, la RM, etc. proporcionan el mejor resultado global para la calidad automática Evaluación de mangos. El rendimiento del						

							clasificador puede ser mayor evaluado utilizando otras métricas como precisión, medida de f, recuperación junto con la tasa de precisión.						
29	2016	Identificación automática de defectos y sistema de clasificación para manzanas 'Jonagold'	Clasificación manual de los productos agrícolas.	Se describe un método para calificar manzanas `Jonagold 'basadas en características extraídas de defectos.	La base de datos que consta de imágenes multiespectrales. Se utiliza el método de agrupación Fuzzy C-Means (FCM) se utiliza para la segmentación de defectos, las características de la parte defectuosa se extraen utilizando el método de Histograma de gradientes orientados (HOG) y la clasificación de manzanas se realiza mediante el uso de la Máquina de vectores de soporte multiclase (MSVM).	Se obtuvo una de precisión de 97.5 % para calificación de dos categorías (saludable y defectuosa) y 94.66% para calificación de múltiples categorías (manzanas saludables, manzanas con defectos leves y manzanas con defectos graves).	Un esquema de calificación automático basado en la visión por computadora para Se presenta la fruta de manzana 'Jonagold'. El enfoque heurístico. Se utiliza para obtener los parámetros de entrada para el trabajo. Los Los defectos se segmentan utilizando el algoritmo FCM. Las características son extraídas del segmento de defecto de la imagen usando HOG. La tasa de reconocimiento más alta del 97.5% se observa con MSVM Para clasificación de dos categorías y 94.66% para multicategoría. Clasificación (manzanas sanas, manzanas ligeramente defectuosas y manzanas muy defectuosas). El trabajo actual se limitaba solo a Variedad de manzana 'Jonagold'. El trabajo futuro es aplicar el	**Manzana**	**Color y textura**	**RGB**	**MSVM**	Cámara digital	Procesamiento de imágenes

							trabajo. A diferentes variedades de manzana						
30	2017	Modelo difuso optimizado de enjambre de partículas para la clasificación de la madurez del banano	La clasificación de la madurez es una tarea importante en la poscosecha de banano (Musa sp.) Para regular el tratamiento de maduración.	Se presenta un modelo difuso para clasificar el nivel de fruta de plátano en etapas maduras, maduras y demasiado maduras. El tono pico y el área marrón normalizada son las características de la región de interés extraída del canal de tono y los colores opuestos	El algoritmo de árbol de clasificación y regresión se aplica para modelar los intervalos del espacio de características y la base de reglas para el sistema difuso. Los parámetros del modelo difuso están sintonizados con la técnica de optimización de enjambre de partículas. El trabajo propuesto se evalúa en la base de datos MUSA que comprende muestras de banano en diferentes etapas de maduración.	El modelo propuesto se evalúa en las imágenes de la base de datos MUSA desarrollada específicamente para las variedades Monthan y Rasthali en etapas maduras, maduras e inmaduras. Se realiza un análisis exhaustivo del método propuesto contra diferentes métodos existentes. Se encontró que el método FMCBR propuesto tiene una mejor tasa de reconocimiento promedio de 93.11%, lo que supera a otros métodos existentes. Las ventajas del FMCBR propuesto son: modelado único, vector de características simples y cortas y base de reglas pequeña	Se desarrolló un sistema difuso optimizado de enjambre de partículas para la clasificación del nivel de maduración del banano en el trabajo propuesto con la combinación de dos características simples: el tono máximo y el área marrón normalizada (NBA). Estas dos características hacen que el algoritmo sea robusto frente a la traducción, rotación, sca e iluminación invariante. Se toma una decisión sobre la maduración del banano mediante un marco de 8 reglas difusas que se acuñan a partir del árbol de decisión.	**banano**	**Color**	**L*a*b***	**Árboles de decisión**	Cámara digital	Procesamiento de imágenes

				de CIEL*a*b*. En un modelado difuso, la definición de las etiquetas lingüísticas, su asignación a los intervalos apropiados y la construcción de la base de reglas juegan roles vitales.									
31	2017	Identificación y conteo de manzanas maduras basadas en la red neuronal de BP feed forward	La clasificación de frutas es una tarea onerosa y tediosa debido a innumerables frutas. El enfoque tradicional para la detección y clasificación de la fruta y su nivel de madurez se basa en la observación a simple vista de los	Se ha propuesto un método para detectar y clasificar automáticamente el nivel de madurez de la fruta de manzana, ya sea madura o inmadura en función de sus característi	Las imágenes de la manzana se redimensionan y las Técnicas de procesamiento de imágenes se aplican para la extracción de los componentes del color de la manzana (R, G, B). La red neuronal artificial se usa como un clasificador para identificar y contar las manzanas maduras e inmaduras utilizando componentes de color.	El modelo propuesto tiene una precisión del 98,1%, cuando todos los tres atributos se utilizan como entrada.	Se planteó un método para el reconocimiento automático y conteo de frutas de manzana madura e inmadura a partir de imágenes. El método sigue tres pasos principales, que son: preprocesamiento, extracción de características y clasificación de madurez. El trabajo se realizó entrenando un conjunto de datos de entrada. Después del preprocesamiento, la etapa de extracción de características se aplica a cada imagen capturada	**Manzana**	**Color**	**RGB**	**red neuronal de BP feed forward**	Cámara digital	Procesamiento de imágenes

			expertos, que consume tanto tiempo como causa fatiga ocular.	cas de color.			redimensionada. El espacio de características se crea utilizando los atributos extraídos. Se desarrolla un modelo de red neuronal para el reconocimiento del color. De los resultados experimentales, las simulaciones muestran que la precisión para el nivel de madurez es de 98.1%. Para futuras investigaciones, se pueden agregar atributos de forma y textura en el espacio de la característica y en lugar de una sola fruta; Se puede tomar en consideración un grupo de frutas o frutas en la planta para aumentar la precisión y la eficiencia del modelo. Este método puede ser utilizado por los agricultores para evaluar el tiempo exacto de cosecha de la fruta y se pueden tomar las medidas de precaución necesarias para proteger la fruta de varias enfermedades en el futuro. Esto a su vez aumentará el rendimiento de la manzana.						

32	2047	Reconocimiento automático de frutas a partir de imágenes naturales con características de color y textura.	La recolección automatizada o asistida por robot es un dominio emergente de la investigación que combina los aspectos de la visión artificial y la inteligencia de la máquina. Esta investigación se puede usar en el monitoreo, clasificación y recolección de frutas para asegurar una cadena de producción más rápida	Este documento tiene como objetivo analizar los métodos populares de cosecha automática, la categorización de las frutas y propone un nuevo enfoque que supera algunos de los inconvenientes de los métodos anteriores. El enfoque propuesto tiene en cuenta diferentes tipos de frutas.	El objetivo principal es encontrar un método para clasificar estos diferentes tipos de frutas de manera precisa y eficiente. Las imágenes se preprocesan para separar la fruta en primer plano del fondo. Las características de textura de la Matriz de coexistencia de nivel de gris (GLCM) y las características estadísticas de color se extraen de la imagen segmentada. Dos tipos de características se combinan en un único descriptor de características. Se entrena un modelo de clasificación de Máquina de vectores de soporte (SVM) usando estos descriptores de características extraídos del conjunto de datos de entrenamiento. Una vez entrenado, el modelo se puede usar para predecir la categoría de una imagen sin etiqueta del conjunto de validación. El enfoque propuesto también funciona mejor para sistemas embebidos y computadoras de una sola placa, ya que realiza las compensaciones de estos dispositivos.		En este trabajo se presentó un método de segmentación eficiente, así como una mejor técnica de clasificación de frutas en el medio natural. Ambiente, se propone. El método propuesto utiliza el estado Técnica de segmentación a nivel de imagen para el fondo. Eliminación. Este método de segmentación no solo depende de Color, pero también depende de la información de borde. Conjunto Las características de textura y color se utilizan para crear una clasificación. Modelo utilizando SVM. El método propuesto es realizar con 83.33% de precisión general. Demuestra un equilibrio entre Precisión y tiempo de ejecución.	**Frutas**	**Color y textura**		**SVM**	-	-

33	2017	Detección automática de moretones en tiempo real en frutas (Apple) usando una cámara térmica	Las nuevas técnicas protegidas y rápidas para evaluar frutas tienen un lugar crítico en la economía agrícola. En la actualidad, los métodos tradicionales de clasificación se han utilizado ampliamente. Sin embargo, el alto costo y algunas inconsistencias en la guía de la industria posterior a la cosecha llevaron a aplicaciones de automatización en las operaciones de clasificación. Recientes, los Compromisos se inclinan hacia los marcos de mecanización para expandir el	En este estudio, se propone la evaluación automática mediante el uso de una cámara térmica y un método de procesamiento de imágenes modernizado.	En este estudio, se propone la evaluación automática mediante el uso de una cámara térmica y un método de procesamiento de imágenes modernizado. Es un trabajo muy tedioso y frenético monitorear el hematoma de la fruta manualmente y el proceso que consume mucho tiempo, por lo que se usa BDS (sistema de detección de hematomas) para la detección de enfermedades de la fruta. La tarea de inspección humana tediosa para clasificar las frutas se reduce diseñando un sistema automatizado que consiste en algoritmos desarrollados y plataformas de transporte.	Este sistema consta de dos partes principales de software y Hardware, el software no es más que una ANN (Artificial Red neuronal) algoritmo y hardware es transportador Sistema de clasificación de frutas basado. Los resultados se muestran en "Higo. 3”muestra el resultado de agrupamiento de la fruta. "Higo. 4,5 " Muestra el resultado de la detección de contusiones y no contusiones.	Se ha 4probado algunos cálculos de actividad para La decisión de hematomas en manzana por coexistencia valores de característica de ocurrencia. El efecto de la región magullada De manzana no era perceptible a simple vista. Por lo tanto Podemos ampliar prototipos de hardware y software. Algoritmo para captura, rotación y detección automática. De moretones en manzana. El método da mejor resultado en Características de cálculo de la matriz de co-ocurrencia. Estos datos Son promedio y comparados con magullados y no magullados. Característica promediada con datos en cada sección de la misma fruta. Esto dispone de subjetividad de las técnicas habituales. y los errores humanos provocados. Sistema de transporte reducido Personal del centro. Hemos utilizado cámara térmica para Detectar el desorden interno de la manzana. Trabajando en real tiempo utilizando ANN obtenemos suficiente velocidad y exactitud. Hemos	**Pepino**	**Color y textura**	**L*a*b***	**ANN**	cámara térmica	Procesamiento de imágenes

			límite de trabajo y disminuir los gastos de trabajo. Las inconsistencias asociadas con la calificación manual disminuyen cuando se usan sistemas de clasificación automatizados. Por lo tanto, la tasa de error y los costos disminuyen a medida que aumenta la velocidad. Como se conoce el tamaño, la forma, el sombreado y el tejido son criterios fundamentales del procedimiento de clasificación.				comprobado la eficiencia de la imagen de la cámara web. Y la eficiencia de la imagen de la cámara térmica. Resultados de la térmica Las cámaras son realmente mejores que los resultados de la cámara web. El procesamiento y análisis de imágenes son reconocidos por visión por computador. Tediosa tarea de inspección humana será Reducido por series de operaciones de procesamiento						

34	2017	Recuperación de imágenes basada en contenido para el reconocimiento de frutas de múltiples objetos utilizando k-means y k-vecino más cercano	Clasificación manual de los productos agrícolas.	Se propone un método para clasificar distintas frutas utilizando las características de forma y color	El proceso de reconocimiento de fruta consta de 3 etapas, a saber, extracción de características, agrupación y reconocimiento. Cada etapa utiliza diferentes métodos. El proceso de extracción de color mediante el método del Histograma de color difuso (FCH) y la extracción de la forma utilizando el método Momento Invariants (MI). El proceso de agrupamiento utiliza el algoritmo de agrupamiento de K-Means. El proceso de reconocimiento utiliza el método k-NN. El proceso de recuperación de imágenes basada en contenido (CBIR) utiliza funciones de imagen (contenido visual) para realizar búsquedas de imágenes desde la base de datos.	Los resultados experimentales y el análisis del sistema de reconocimiento de fruta obtuvieron una precisión de 92.5% para imágenes de un solo objeto y 90% para la imagen de múltiples objetos.	El método CBIR logró reconocimiento para lograr la el valor de precisión más alto del 92.5% para imágenes de un solo objeto y 90% en promedio usando imágenes de múltiples objetos. El más alto Resultados de precisión obtenidos con una imagen del objeto de 2 objetos. con K = 7. Entonces, se puede concluir que: 1. Determinar el valor de K afecta el resultado de una Reconocimiento de imágenes multi-objeto significativamente. 2. Cuanto menor sea el objeto, mayor precisión de reconocimiento valor. Cuantos más objetos, menor reconocimiento. Valor de exactitud 3. La imagen que tiene una saturación de color, píxeles divididos, formas. inadecuado, y la falta de ingresos sería difícil de Detecta la luz y la reconoce. 4. El valor de la característica de color resultante tiene fuertemente influyó en las reglas sobre la extracción de características de color método FCH. 5. El agrupamiento puede acelerar el proceso de	**Frutas**	**Forma y color**	**L*a*b***	**KNN**	Cámara digital	Procesamiento de imágenes

							reconocimiento. 6. El tiempo de computación es dinámico. Sugerencias para un mayor desarrollo: 1. La investigación adicional puede desarrollar para reconocer más Imágenes de frutas, como manzanas y otros tipos de manzanas. 2. El software puede ser desarrollado agregando una característica Extracción que se basa en la textura. 3. La investigación se puede desarrollar multiplicando objetos en Imágenes multi-objeto con posiciones cambiantes. 4. La investigación puede desarrollarse agregando una variable más. Papelera de color al método FCH.						
35	2017	Identificación del tamaño y madurez de la fruta a través de imágenes de frutas utilizando OpenCV-Python y Rasberry Pi	El color y el tamaño son una de las características más importantes para una clasificación precisa de madurez de las frutas. Los pequeños agricultores utilizan la evaluación	Identificación del tamaño y madurez de la fruta a través de imágenes de frutas utilizando OpenCV-Python y Rasberry Pi	Este trabajo se centra en la identificación de la madurez de la fruta del mango. Raspberry Pi es una computadora pequeña, que es lo suficientemente potente como para ejecutar un algoritmo de procesamiento de imágenes que se elige para este sistema. El algoritmo de procesamiento de imágenes desarrollado puede determinar el tamaño de la fruta y aplicar el agrupamiento de K-means	El sistema es capaz de calcular el tamaño aproximado de la Fruta. Además, se puede determinar la madurez del fruto. Simplemente utilizando el color dominante de la fruta. El sistema también es Capaz de detectar la madurez del fruto a través del color. K-significa agrupación para un proceso de calificación adicional. Por último, por utilizando el histograma de OpenCV-Python, el sistema puede hacer una comparación y comprobación de la similitud de vencimiento utilizando OpenCV-Python histograma de la fruta mango.	En conclusión, el sistema de clasificación de fruta que ha sido Aplicado por FAMA ha sido estudiado. Hay 6 vencimientos de índice establecido por la fama. A continuación, el sistema de clasificación de fruta existente ha sido Estudiado a través de la revisión de la literatura. La Raspberry Pi funciona Perfectamente con Python y OpenCV-Python.	**Mango**	**Forma y color**	**RGB**	**K-MEANS**	Cámara digital	Procesamiento de imágenes

			manual a través de la observación visual para clasificar la madurez de su elección. Que según FAMA hay seis índices de madurez. El proceso repetitivo es tedioso y es propenso al error humano.		para determinar el color de la fruta		Además, el programa en ejecución y la potencia de procesamiento es rápida con sólo usar 5V y 1Ghz de RAM. Además, puede ser utilizado con la misma pantalla en una computadora portátil al mismo tiempo y no hay necesidad para usar un monitor, teclado y mouse separados. A continuación, utilizando Python con OpenCV-Python, el algoritmo de k-means para encontrar El color dominante de la fruta, tamaño de la fruta con Euclides. Distancia y comparando la madurez del fruto utilizando OpenCV- El histograma de Python ha sido analizado. Por lo tanto, un tamaño de fruta y La identificación de la madurez del color con Raspberry Pi ha sido desarrollado. El sistema es capaz de calcular el tamaño aproximado. De la fruta. El sistema también es capaz de detectar la madurez de la Fruta a través del color utilizando K-medias agrupación para más proceso de calificación						

36	2017	Clasificación de imágenes basada en la región utilizando técnicas de transformación de cuencas hidrográficas.	El aumento masivo en el grado de datos en los repositorios de datos en línea requiere la necesidad de una gestión y recuperación de datos eficiente. Los algoritmos actuales del estado de la técnica son expertos en la recuperación de información relacionada con datos de tipo de texto y con una tasa de éxito de casi el 99%. Sin embargo, la recuperación de información basada en datos multimedia como imágenes necesita más revisiones para obtener el resultado esperado.	Proponen un método para clasificar las imágenes según la forma y las características regionales.	En este trabajo, el objetivo de la investigación es clasificar las imágenes según la forma y las características regionales. Las categorías de imágenes consideradas incluyen frutas y verduras. La técnica propuesta para la clasificación de imágenes emplea la transformación de la cuenca hidrográfica para la segmentación y desde la cual se calculan las características de la wavelet de Haar y se dirigen para la clasificación utilizando el clasificador SVM, KNN y Naïve Bayes.		Clasificación de imágenes en la categoría basada en la región es uno de los problema de investigación interesante empleables principalmente para Optimizando la búsqueda de imágenes y la recuperación de imágenes variadas. Basado en la forma y características regionales. La corriente Los algoritmos son expertos en la recuperación de información relacionada con Datos de tipo de texto y han ganado éxito. Sin embargo la información la recuperación de datos similares a multimedia requiere muchas revisiones por lo que en El método propuesto hemos considerado las imágenes de frutas, Vegetales, hojas y flores. La técnica propuesta en este El método incluye la transformación de cuenca para la segmentación de qué características de wavelet de Haar se calculan. La clasificación Se realiza utilizando SVM, KNN y Naïve Bayes. El experimento se lleva a cabo en aproximadamente 350 conjuntos de datos de imagen y Según la técnica basada en la votación,	**Frutas**	**Forma y color**	**rgb**	**SVM, KNN y Naïve Bayes.**	Cámara digital	Procesamiento de imágenes

							alrededor del 90% de precisión. se consigue						
37	2018	Reconocimiento de la condición madura, inmadura y escalada de los cítricos anaranjados según la clasificación del árbol de decisión	La naranja, que es la fruta más cultivada en el mundo, se usa comúnmente en las industrias de procesamiento de alimentos para preparar jugos, mermeladas y pulpa de naranja. Con las modernas técnicas de visión artificial, la clasificación manual de frutas se está reemplazando con un enfoque automatizado de bajo costo y coherente.	Método para realizar la clasificación de forma automática de las naranjas utilizando muestras extraídas de imágenes RGB	Este documento presenta un medio para distinguir rápidamente la condición de naranja (madura, inmadura y escamosa o podrida). Se extraen las características de la imagen de la fruta, incluidos el espacio de color RGB y los valores de gris basados en BIC (Clasificación de píxeles del borde / interior). Se ha realizado una investigación sobre la aplicabilidad y el rendimiento de varios algoritmos de clasificación, incluidos Naïve Bayes, Artificial Neural Network y Decision Tree	Las comparaciones entre los resultados de estos algoritmos se han elaborado y se ha observado que la técnica de clasificación de Árbol de Decisión para condiciones de naranja es eficiente que otras técnicas. Los resultados registrados para la precisión, la precisión y la sensibilidad utilizando esta técnica son 93.13%, 93.45% y 93.24% respectivamente.	Este trabajo presentó una clasificación de condición naranja. Sistema prototipo mediante la aplicación de la técnica de procesamiento de imágenes. Se han extraído características significativas y una comparación. Entre la red neuronal, los ingenuos bayes y el árbol de decisiones el algoritmo fue dibujado usando MATLAB R2016a. Lo más Se han logrado resultados efectivos utilizando el Árbol de Decisión. Algoritmo de clasificación. La precisión, la precisión media, y sensibilidad promedio medida usando la clasificación del Árbol de Decisión es 93.13%, 93.45% y 93.24% respectivamente. De ahí, el estudio. Indica que la técnica de clasificación	**Naranja**	**Color y forma**	**RGB**	**Naïve Bayes, Artificial Neural Network y Decision Tree**	Cámara digital	procesamiento de imágenes

							del Árbol de Decisión en Combinación con la Clasificación de píxeles de borde / interior (BIC) y las características del color de la fruta tienen un buen potencial para identificar Condiciones de naranja es decir, maduras, inmaduras y escamas						
38	2018	Clasificación basada en el procesamiento de imágenes de pardeamiento enzimático en manzanas picadas	Las manzanas son una de las frutas más comunes en el planeta. Es rico en hierro, fibra, antioxidantes y otras cualidades nutritivas; que son increíblemente importantes para el cuerpo humano y el cerebro. La calidad de una manzana se ve afectada una vez cortadas	Este artículo presenta un algoritmo basado en el procesamiento de imágenes no destructivo que identifica la presencia de pardeamiento enzimático en manzanas picadas para la determinación de la pérdida de nutrientes.	El conjunto imperativo propuesto de este algoritmo de procesamiento de imágenes lo hace flexible, automático y no destructivo. La cuantificación del pardeamiento enzimático en manzanas picadas se ha obtenido con alta precisión utilizando este método basado en imágenes propuesto. El aprendizaje automático basado en la selección estratégica de características estadísticas discriminatorias de manzanas cortadas extraídas en el dominio de wavelet lo convierte en un enfoque novedoso.	El enfoque propuesto es un método basado en el procesamiento de imágenes no destructivo para la identificación de pardeamiento enzimático en manzanas picadas. La segmentación automática de la eliminación de fondo se ha realizado mediante el uso del método de agrupación de K-means que dio una eficiencia muy alta. Las características obtenidas de los coeficientes horizontales de la descomposición de wavelets de tercer nivel representan una variación monotónica en los parámetros. Se ha realizado una clasificación SVM basada en binarios y se ha alcanzado el 85% de precisión. Estas características discriminatorias obtenidas del experimento establecen una correlación entre el pardeamiento enzimático como resultado de la formación de enzimas en manzanas picadas y los minutos de almacenamiento	Este trabajo abre nuevas dimensiones de investigación en el área de pruebas de calidad de muestras de fruta en aplicaciones en tiempo real. En lo que respecta a las perspectivas futuras, se puede tomar un conjunto de datos más grande y se puede diseñar un prototipo para las variedades de manzanas cortadas irregularmente. Este método también se puede utilizar como una herramienta de evaluación para la identificación de la frescura en una muestra de fruta.	**Manzana**	**Color**	**RGB**	**K-MEANS**	Cámara digital	

39	2018	Sistema de reconocimiento de especies de durian basado en representaciones de formas globales y vecinos K-Nearest	Muchos sistemas de reconocimiento de frutas hoy en día están diseñados para clasificar diferentes tipos de frutas, pero no hay un sistema de reconocimiento de frutas basado en el contenido que se centre en las especies de durián. El durián, conocido como el rey de las frutas tropicales, tiene pocas características similares entre las diferentes especies en las que la piel tiene casi el mismo color de verde a marrón amarillento con formas de espinas ligeramente diferentes y es difícil diferenciarla	Este trabajo tiene como objetivo contribuir a un reconocimiento automático de especies de durián basado en contenido que será capaz de ayudar a los usuarios a diferenciar varias especies de durian.	Se debe resaltar que si bien es cierto existe pocos descriptores de formas globales basados en contornos y regiones, como área, perímetro, y la circularidad se calcula como vectores de características y se utiliza el algoritmo K-Nearest Neighbors para clasificar el durián en función de las características extraídas. Se utiliza una validación cruzada de 10 veces para evaluar el sistema propuesto	Los resultados experimentales han demostrado que el método de extracción de características propuesto para el sistema de reconocimiento de especies de durián ha obtenido con éxito una tasa de reconocimiento positiva del 100%.	El método de características de forma propuesto mediante el uso de descriptores de forma globales simples ha logrado con éxito una tasa de reconocimiento del 100% basada en la validación cruzada de 10 veces. El reconocimiento de las especies de durian ahora se puede hacer fácilmente usando el sistema cargando una imagen de una especie desconocida de durian en lugar de buscarla en línea por texto. Para trabajos futuros, planeamos expandir el conjunto de datos incluyendo más imágenes para cada especie y explorando otras especies de durián. También se considerará una licencia de aplicación móvil para facilitar a los consumidores generales el uso de la aplicación durante la compra de durian.	**Durian**	**forma y color**	**HSV**	**KNN**	Cámara digital	procesamiento de imágenes

			s con los métodos actuales. A veces, incluso para los consumidores en general, es difícil diferenciar las especies de durián por sí mismas.										
40	2018	Detección de café (Coffea Arabica L.) eventos de floración secuencial basados en la segmentación de la imagen	La detección secuencial de los eventos de floración del café y la estimación de la densidad de la flor es esencial para predecir el tiempo de maduración y el rendimiento del café.	En este estudio, se destaca los eventos de floración de café basados automáticamente en densidades de flores estimadas en imágenes digitales de series de tiempo de alta espacialidad.	Para realizar esta propuesta se ha utilizado un método de segmentación de flores basado en regiones de múltiples escalas. El área de estudio es una plantación de café en Lujiangba, en la provincia china de Yunnan. Hay 5 eventos de floración en el período de floración del café. Una cámara digital obtuvo 24 imágenes RGB en cada momento de toma del día (8:00, 9:00, 10:00, 11:00, 12:00, 13:00, 14:00, 15:00, 16:00, 17:00, 17:30) ajustando automáticamente el sensor con 3 ángulos de depresión y 8 ángulos de azimut durante el período de floración del café desde el 1 de marzo hasta el 31 de mayo. Para segmentar las flores en una sola imagen, las regiones multiescaladas se generaron principalmente mediante una segmentación de súper píxeles de igual tamaño y un posterior proceso de fusión de súper píxeles. A	La validación en 10 veces de los modelos en muestras de entrenamiento. Demuestra que FSS SVM clasificador tiene el recuerdo de 60.74%, precisión de 83.54% e IoU de 54.25%, y el El clasificador FSSM SVM tiene una recuperación de 76.14%, precisión de 81.81% e IoU de 65.11%. Así, el modelo FSSM SVM es Superior al modelo FSS SVM en la validación del conjunto de entrenamiento. Sin embargo, el rendimiento de estos dos algoritmos sigue siendo necesario. Para ser evaluado en nuevas imágenes de prueba para probar su generalización. habilidades	En este artículo, se presentó un método realizar una segmentación de flores de café. Método basado en regiones multiescala para café automático. Detección de eventos florales. Los resultados experimentales muestran que El mejor ángulo de depresión de las imágenes para la segmentación de flores. Es el ángulo de depresión de 77.5 grados, y luego el propuesto. El método FSSM hace el mejor rendimiento y eficiencia. Bajo ese ángulo óptimo con 84.89% de memoria, 74.83% Precisión y 65.46% IoU. Por otra parte, la variada floración. Los eventos se pueden demostrar trazando la proporción de flores. Estimado por el algoritmo de segmentación de la flor en el tiempo. Serie de	**Café**	**Color**	**RGB**	**SVM**	Cámara digital	Procesamiento de imágenes

					continuación, los vectores de características de cada región fueron extraídos por momentos de color (CM) del operador y los patrones binarios locales operador (LBP). Posteriormente, se aplicó el clasificador de la máquina de vectores de soporte (SVM) entrenado en estas características para reconocer las regiones florales. Por lo tanto, el porcentaje de píxeles de flor referidos como proporción de flor (FP), que puede estimar la densidad de la flor basada en la imagen, se calculó en preparación para detectar eventos de floración de imágenes de series de tiempo. En esta etapa, los coeficientes de memoria, Se emplearon la precisión y la intersección sobre la unión (IoU) para evaluar el rendimiento de los métodos de segmentación en 14 imágenes de prueba en tres ángulos de depresión y luego se puede determinar el mejor algoritmo de segmentación de la flor y el ángulo óptimo. En la etapa de detección de eventos de floración, se calcularon y representaron gráficamente las FP de diferentes imágenes multitemporales de tiempo de disparo bajo el ángulo óptimo de depresión. Luego, se seleccionó un umbral de FP, K, para determinar si una		imágenes. Aplicando el umbral de la flor. Proporción, el rendimiento de 11 imágenes de series de tiempo fue Evaluado y muestra que la secuencia de imágenes se disparó a las 13:00. Muestra el mejor resultado robusto bajo iluminación compleja, con 65.00% de recuerdo, 100% de precisión y 65% de IoU. Nosotros Creemos que el método puede proporcionar floración informativa. Resultados para futuras investigaciones sobre la calidad de las flores y la madurez de la fruta. Predicción y estimación del rendimiento.						

					imagen está en un día de floración. Para determinar el mejor momento de disparo para la floración								
41	2018	Método de clasificación de manzanas basado en características de color y defecto	La clasificación automática de manzanas es una aplicación importante de la tecnología de visión artificial en la detección de productos agrícolas	En este documento, estudiamos el método de clasificación de manzanas basado en las características de color y defecto.	Primero, las imágenes de manzana basadas en RGB capturadas se transforman al modelo de color HIS. Luego, la segmentación entre la fruta y el fondo se realiza a través del algoritmo de Oust para los valores H de la imagen, y la característica de color se extrae mediante el rango apropiado de valores H. Además, el algoritmo de detección de borde Canny con umbral de histéresis se emplea para extraer la información de borde del área del defecto de los valores I de la imagen de la fruta, luego el área del defecto se segmenta por operación morfológica. Finalmente, como entrada, las cantidades características del color de la manzana y el defecto de la superficie se envían al modelo SVM basado en la optimización del enjambre de partículas.	A partir de los resultados de la clasificación, podemos ver que el estado de los 100 conjuntos de datos de prueba es altamente consistente con el estado de clasificación artificial, y las tasas de precisión de clasificación son 90%, 93.33%, 86.67%, 95%, respectivamente, y la tasa de precisión promedio es del 91%	De acuerdo con las imágenes de manzana de este experimento, esta propuesta utiliza el algoritmo de Oust para tonificar los valores de las imágenes y lograr la segmentación de la fruta y el fondo. Al mismo tiempo, los valores de tono se utilizan para extraer la característica de color. Para los defectos de la superficie del fruto, la propuesta. Adopta el algoritmo de detección de bordes Canny con histéresis. Umbral para extraer la información del borde del área del defecto. A partir de los valores I de la imagen del fruto, y el área del defecto es segmentado por la operación morfológica. El método puede efectivamente extraer color de fruta de manzana y defecto de superficie.	**Manzana**	**color y defecto**	**HSI**	**SVM (bordes Canny)**	Cámara digital	Procesamiento de imágenes

							Características respecto a la cantidad de características extraídas, la precisión de la clasificación es de hasta el 91% al establecer y Entrenamiento del modelo SVM basado en la optimización de partículas enjambre. Lo que prueba la viabilidad de la g es el método de clasificación.						
42	2018	Clasificación de enfermedades y clasificación de naranja mediante aprendizaje automático y lógica difusa	Clasificar las enfermedades de las cascaras de naranja para predecir males y mejorar la calidad de selección	Este artículo sugiere un sistema basado en la visión por computadora que tiene la capacidad de identificar deformidades en las frutas naranjas y también organiza el tipo de falla que apareció en la superficie de las frutas naranjas.	Los síntomas de la marca de defecto implican la gravedad de la enfermedad y recomiendan el enfoque óptimo para tratar la enfermedad. También se requiere diagnosticar la enfermedad correctamente antes de un gran daño al proporcionar un tratamiento adecuado. Además, se requiere una estimación de la gravedad de la enfermedad para aplicar una cantidad adecuada de pesticidas para evitar la contaminación ambiental y la carga económica.	Se utilizó el algoritmo SVM de clases múltiples con agrupación de K-medias para la clasificación de enfermedades con el 90% de precisión y la lógica difusa para calcular el grado de gravedad de la enfermedad.	En este trabajo, clasificamos con éxito los diferentes tipos de enfermedad con 90% de precisión y también computar. La severidad de la enfermedad de cuatro tipos de naranja enferma. Exitosamente. Esta investigación puede extenderse a Incrementa la precisión utilizando la técnica de computación suave. y validar con más cantidad de muestra	**Naranja**	**Color**	**RGB to L*a*b***	**SVM**	-	-

43	2018	Clasificación de la calidad y madurez de los mangos cosechados según las técnicas de aprendizaje automático	Mencionan que es muy importante hacer una clasificación adecuada de las frutas para aumentar las ganancias de las industrias agrícolas y alimentarias	Se propone una técnica novedosa para la clasificación del mango automáticamente de acuerdo con las características de las frutas consideradas para la calidad del grado de madurez.	Para la propuesta se utiliza las características son tamaño, forma, color y superficie del píxel. En este sistema, los mangos se clasifican en cuatro tipos, como Green Mango, Yellow Mango y Red Mango, que se basan en el método de aprendizaje automático. Este sistema considera los valores RGB del tamaño y forma de los mangos. El análisis posterior se utiliza para obtener una buena probabilidad. Esto ayuda a entrenar el sistema para detectar la madurez apropiada de los mangos. Este experimento se realiza en dos métodos de aprendizaje automático, es decir, Naive Byes y SVM (Support Vector Machine) comparan el rendimiento de ambos en función de la precisión y los píxeles defectuosos	Este estudio resume aquí que los Naive Byes con técnicas de análisis posterior se pueden aplicar en las imágenes de mangos para el grado de acuerdo con su madurez, tamaño y forma. En qué técnicas de procesamiento de imágenes se han utilizado para obtener los valores exactos de las características de los mangos, que son la forma, el tamaño, el color y la piel de los mangos, a fin de preparar una entrada para los ingenuos con técnicas de análisis posterior.	El sistema propuesto es capaz de clasificar la fruta en función de la madurez y consideramos las diferentes características de la fruta del mango. Para ello utilizamos metodología de aprendizaje automático. Aquí podemos decir que el sistema da mejores resultados ya que usamos el análisis posterior para mejorar la precisión del conjunto de datos de entrenamiento, y también medir con precisión el atributo de la imagen de prueba. Nuestro sistema funciona solo para un área de superficie particular, considere detectar el píxel defectuoso. Si existe otro defecto que no sea el área de superficie, no podemos detectarlo. Para esto, en el futuro, debe considerar la vista de rotación o la vista de superficie diferente.	**Mango**	**Color, forma y textura**	**RGB**	**Naive Byes y SVM**	-	-

REFERENCIAS

[1] R. Amirulah, M. M. Mokji, and Z. Ibrahim, "Starfruit color maturity classification using cr as feature," in *2010 Sixth International Conference on Signal-Image Technology and Internet Based Systems*, pp. 93–97, Dec 2010.

[2] J. P. D'Amato, C. García Bauza, and G. Boroni, "Color based fruits classification using GPU," *IEEE Latin America Transactions*, vol. 9, no. 3, pp. 366–370, 2011.

[3] G. Moradi, M. Shamsi, M. H. Sedaaghi, S. Moradi, and M. R. Alsharif, "Apple defect detection using statistical histogram based em algorithm," in *2011 19th Iranian Conference on Electrical Engineering*, pp. 1–6, May 2011.

[4] J. Suriya Prakash, K. Annamalai Vignesh, C. Ashok, and R. Adithyan, "Multi class support vector machines classifier for machine vision application," in *2012 International Conference on Machine Vision and Image Processing (MVIP)*, pp. 197–199, Dec 2012.

[5] S. Mohamed Mansoor Roomi, R. Jyothi Priya, S. Bhumesh, and P. Monisha, "Classification of mangoes by object features and contour modeling," in *2012 International Conference on Machine Vision and Image Processing (MVIP)*, pp. 165–168, Dec 2012.

[6] J. Gironés, J. Casas, J. Minguillón, and R. Caihuelas, *Minería de datos: modelos y algoritmos*. Editorial UOC, 2017.

[7] R. K. Patel, K. R. Jain, and T. R. Patel, "Non-destructive quality evaluation technique for processed phyllanthus emblica(gooseberry) using image processing," in *2013 International Conference on Communication Systems and Network Technologies*, pp. 69–73, April 2013.

[8] G. Moradi, M. Shamsi, M. H. Sedaaghi, and S. Moradi, "Apple defect detection using statistical histogram based fuzzy c-means algorithm," in *2011 7th Iranian Conference on Machine Vision and Image Processing*, pp. 1–5, Nov 2011.

[9] F. Medina, B. Nono, H. Banda, and A. Rosales, "Classification of solid objects with defined shapes using stereoscopic vision and a robotic arm," in *2012 VI Andean Region International Conference*, pp. 226–226, Nov 2012.

[10] M. Jhuria, A. Kumar, and R. Borse, "Image processing for smart farming: Detection of disease and fruit grading," in *2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013)*, pp. 521–526, Dec 2013.

[11] H. M. Zawbaa, M. Hazman, M. Abbass, and A. E. Hassanien, "Automatic fruit classification using random forest algorithm," in *2014 14th International Conference on Hybrid Intelligent Systems*, pp. 164–168, Dec 2014.

[12] M. Khojastehnazhand, M. Omid, and A. Tabatabaeefar, "Development of a lemon sorting system based on color and size," *African Journal of Plant Science*, vol. 4, no. April, pp. 122–127, 2010.

[13] X. Liming and Z. Yanchao, "Automated strawberry grading system based on image processing," *Computers and Electronics in Agriculture*, vol. 71, pp. S32–S39, 2010.

[14] Nur Badariah Ahmad Mustafa, K. Arumugam, S. K. Ahmed, and Z. A. M. Sharrif, "Classification of fruits using probabilistic neural networks - improvement using color features," in *TENCON 2011 - 2011 IEEE Region 10 Conference*, pp. 264–269, Nov 2011.

[15] D. Savakar, "Identification and classification of bulk fruits image using artificial neural networks," *International Journal of Engineering and Innovative Technology*, vol. 1, no. 3, pp. 36–40, 2012.

[16] N. Alavi *et al.*, "Date grading using rule-based fuzzy inference system," *Journal of Agricultural Technology*, vol. 8, no. 4, pp. 1243–1254, 2012.

[17] M. Suresha, N. Shilpa, and B. Shoumya, "Apples Grading based on SVM Classifier," *International Journal of Computer Applications on National Conference on Advanced Computing and Communication-NCACC*, pp. 27–30, 2012.

[18] T. R. B. Razak[1], M. B. Othman, M. N. bin Abu Bakar, K. A. bt Ahmad, and A. R. Mansor, "Mango grading by using fuzzy image analysis," in *International Conference on Agricultural, Environment and Biological Sciences (ICAEBS'2012) May 26-27, 2012 Phuket*, 2012.

[19] C. Zhang, L. Chen, W. Huang, Z. Guo, and Q. Wang, "Apple stem-end/calyx identification using a speckle-array encoding pattern," in *2012 IEEE 11th International Conference on Signal Processing*, vol. 2, pp. 1110–1114, Oct 2012.

[20] P. Deepa and S. Geethalakshmi, "A Comparative Analysis of Feature Extraction Methods for Fruit Grading Classifications," *International Journal of Emerging Technologies in Computational and Applied Sciences (IJETCAS)*, pp. 221–225, 2013.

[21] R. S. S. Kumari and V. Gomathy, "Fruit classification using statistical features in svm classifier," in *2018 4th International Conference on Electrical Energy Systems (ICEES)*, pp. 526–529, Feb 2018.

[22] S. Lu, Z. Lu, S. Aok, and L. Graham, "Fruit classification based on six layer convolutional neural network," in *2018 IEEE 23rd International Conference on Digital Signal Processing (DSP)*, pp. 1–5, Nov 2018.

[23] A. Kanade and A. Shaligram, "Development of machine vision based system for classification of guava fruits on the basis of cie1931 chromaticity coordinates," in *2015 2nd*

International Symposium on Physics and Technology of Sensors (ISPTS), pp. 177–180, March 2015.

[24] S. Raj and D. S. Vinod, "Automatic defect identification and grading system for 'jonagold' apples," in *2016 Second International Conference on Cognitive Computing and Information Processing (CCIP)*, pp. 1–5, Aug 2016.

[25] I. B. Mustaffa and S. F. B. M. Khairul, "Identification of fruit size and maturity through fruit images using opencv-python and rasberry pi," in *Proc. Automation and Sciences (ICORAS) 2017 Int. Conf. Robotics*, pp. 1–3, Nov. 2017.

[26] P. Leekul and M. Krairiksh, "A sensor for fruit classification using doppler radar," in *2018 IEEE Conference on Antenna Measurements Applications (CAMA)*, pp. 1–2, Sep. 2018.

[27] Z. M. Khaing, Y. Naung, and P. H. Htut, "Development of control system for fruit classification based on convolutional neural network," in *2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)*, pp. 1805–1807, Jan 2018.

[28] R. Hasan and S. M. G. Monir, "Fruit maturity estimation based on fuzzy classification," in *2017 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*, pp. 27–32, Sep. 2017.

[29] A. Zhu, L. Yang, and Y. Chen, "An fcm-based method to recognize and extract ripe tomato for harvesting robotic system," in *2012 IEEE International Conference on Automation and Logistics*, pp. 533–538, Aug 2012.

[30] S. Mohamed Mansoor Roomi, R. Jyothi Priya, S. Bhumesh, and P. Monisha, "Classification of mangoes by object features and contour modeling," in *2012 International Conference on Machine Vision and Image Processing (MVIP)*, pp. 165–168, Dec 2012.

[31] C. Hung, J. Nieto, Z. Taylor, J. Underwood, and S. Sukkarieh, "Orchard fruit segmentation using multi-spectral feature learning," in *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 5314–5320, Nov 2013.

[32] S. R. Rupanagudi, B. S. Ranjani, P. Nagaraj, and V. G. Bhat, "A cost effective tomato maturity grading system using image processing for farmers," in *2014 International Conference on Contemporary Computing and Informatics (IC3I)*, pp. 7–12, Nov 2014.

[33] N. A. Ibraheem, M. M. Hasan, R. Z. Khan, and P. K. Mishra, "Iunderstanding color models : A review," *ARPN Journal of Science and Technology*, pp. 265–275, 2012.

[34] J. P. D Amato, C. Garcia Bauza, and G. Boroni, "Color based fruits classification using gpu," *IEEE Latin America Transactions*, vol. 9, pp. 346–350, June 2011.

[35] C. E. Huerta-Hernández and H. Sánchez-Cruz, "Chain code histograms for rotation invariance," in *2014 International Conference on Computational Science and Computational Intelligence*, vol. 1, pp. 190–193, March 2014.

[36] K. R. Gavhale, U. Gawande, and K. O. Hajari, "Unhealthy region of citrus leaf detection using image processing techniques," in *International Conference for Convergence for Technology-2014*, pp. 1–6, April 2014.

[37] Seema, A. Kumar, and G. S. Gill, "Automatic fruit grading and classification system using computer vision: A review," in *2015 Second International Conference on Advances in Computing and Communication Engineering*, pp. 598–603, May 2015.

[38] V. Ashok and D. S. Vinod, "A comparative study of feature extraction methods in defect classification of mangoes using neural network," in *2016 Second International Conference on Cognitive Computing and Information Processing (CCIP)*, pp. 1–6, Aug 2016.

[39] N. M. Hussain Hassan and A. A. Nashat, "New effective techniques for automatic detection and classification of external olive fruits defects based on image processing techniques," *Multidimensional Systems and Signal Processing*, p. 1, Mar. 2018.

[40] P. Charoensawan, S. Phongsuphap, and I. Shimizu, "Comparison of fabric color naming using rgb and hsv color models," in *2018 15th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, pp. 1–5, July 2018.

[41] J. DeFranco and P. A. Laplante, "Integrative Literature Review Review and Analysis of Software Development Team Communication Research," *IEEE Transactions on Professional Communication*, vol. 00, no. 00, pp. 1–18, 2017.

[42] M. A. Nuño-Maganda, Y. Hernández-Mier, C. Torres-Huitzil, and J. Jiménez-Arteaga, "Fpga-based real-time citrus classification system," in *2014 IEEE 5th Latin American Symposium on Circuits and Systems*, pp. 1–4, Feb 2014.

[43] Edgar Roa Guerrero and Gustavo Meneses Benavides, "Automated system for classifying hass avocados based on image processing techniques," in *2014 IEEE Colombian Conference on Communications and Computing (COLCOM)*, pp. 1–6, June 2014.

[44] H. Hambali, N. Jamil, S. L. S. Abdullah, and H. Harun, "A rule-based segmentation method for fruit images under natural illumination," in *2014 International Conference on Computer, Control, Informatics and Its Applications (IC3INA)*, pp. 13–18, Oct 2014.

[45] A. Lam, Y. Kuno, and I. Sato, "Evaluating freshness of produce using transfer learning," in *2015 21st Korea-Japan Joint Workshop on Frontiers of Computer Vision (FCV)*, pp. 1–4, Jan 2015.

[46] D. M. Gila, D. A. Puerto, J. G. García, and J. G. Ortega, "Automatic classification of olives for oil production using computer vision," in *2015 IEEE International Conference on Industrial Technology (ICIT)*, pp. 1651–1656, March 2015.

[47] V. Pavithra, R. Pounroja, and B. S. Bama, "Machine vision based automatic sorting of cherry tomatoes," in *2015 2nd International Conference on Electronics and Communication Systems (ICECS)*, pp. 271–275, Feb 2015.

[48] R. Kumar and S. Meher, "A novel method for visually impaired using object recognition," in *2015 International Conference on Communications and Signal Processing (ICCSP)*, pp. 0772–0776, April 2015.

[49] E. Rachmawati, M. L. Khodra, and I. Supriana, "Histogram based color pattern identification of multiclass fruit using feature selection," in *2015 International Conference on Electrical Engineering and Informatics (ICEEI)*, pp. 43–48, Aug 2015.

[50] R. P. Salunkhe and A. A. Patil, "Image processing for mango ripening stage detection: Rgb and hsv method," in *2015 Third International Conference on Image Information Processing (ICIIP)*, pp. 362–365, Dec 2015.

[51] M. Dhakate and Ingole A. B., "Diagnosis of pomegranate plant diseases using neural network," in *2015 Fifth National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG)*, pp. 1–4, Dec 2015.

[52] Z. S. Pothen and S. Nuske, "Texture-based fruit detection via images using the smooth patterns on the fruit," in *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 5171–5176, May 2016.

[53] D. S. Tan, R. N. Leong, A. F. Laguna, C. A. Ngo, A. Lao, D. Amalin, and D. Alvindia, "A framework for measuring infection level on cacao pods," in *2016 IEEE Region 10 Symposium (TENSYMP)*, pp. 384–389, May 2016.

[54] S. Marimuthu and S. M. M. Roomi, "Particle swarm optimized fuzzy model for the classification of banana ripeness," *IEEE Sensors Journal*, vol. 17, pp. 4903–4915, Aug 2017.

[55] S. Lal, S. K. Behera, P. K. Sethy, and A. K. Rath, "Identification and counting of mature apple fruit based on bp feed forward neural network," in *2017 Third International Conference on Sensing, Signal Processing and Security (ICSSS)*, pp. 361–368, May 2017.

[56] S. Jana, S. Basak, and R. Parekh, "Automatic fruit recognition from natural images using color and texture features," in *2017 Devices for Integrated Circuit (DevIC)*, pp. 620–624, March 2017.

[57] D. Jawale and M. Deshmukh, "Real time automatic bruise detection in (apple) fruits using thermal camera," in *2017 International Conference on Communication and Signal Processing (ICCSP)*, pp. 1080–1085, April 2017.

[58] Erwin, M. Fachrurrozi, A. Fiqih, B. R. Saputra, R. Algani, and A. Primanita, "Content based image retrieval for multi-objects fruits recognition using k-means and k-nearest neighbor," in *2017 International Conference on Data and Software Engineering (ICoDSE)*, pp. 1–6, Nov 2017.

[59] M. S. Pawar, L. Perianayagam, and N. S. Rani, "Region based image classification using watershed transform techniques," in *2017 International Conference on Intelligent Computing and Control (I2C2)*, pp. 1–5, June 2017.

[60] A. Wajid, N. K. Singh, P. Junjun, and M. A. Mughal, "Recognition of ripe, unripe and scaled condition of orange citrus based on decision tree classification," in *2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)*, pp. 1–4, March 2018.

[61] M. Arora, M. K. Dutta, C. M. Travieso, and R. Burget, "Image processing based classification of enzymatic browning in chopped apples," in *2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI)*, pp. 1–8, July 2018.

[62] X. Y. Nyon, M. R. Mustaffa, L. N. Abdullah, and N. A. Nasharuddin, "Durian species recognition system based on global shape representations and k-nearest neighbors," in *2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)*, pp. 1–6, March 2018.

[63] H. Peng, J. Huang, H. Jin, H. Sun, D. Chai, X. Wang, B. Han, Z. Zhou, and L. Xu, "Detecting coffee (coffea arabica l.) sequential flowering events based on image segmentation," in *2018 7th International Conference on Agro-geoinformatics (Agro-geoinformatics)*, pp. 1–6, Aug 2018.

[64] Y. Ji, Q. Zhao, S. Bi, and T. Shen, "Apple grading method based on features of color and defect," in *2018 37th Chinese Control Conference (CCC)*, pp. 5364–5368, July 2018.

[65] S. K. Behera, L. Jena, A. K. Rath, and P. K. Sethy, "Disease classification and grading of orange using machine learning and fuzzy logic," in *2018 International Conference on Communication and Signal Processing (ICCSP)*, pp. 0678–0682, April 2018.

[66] D. Pise and G. D. Upadhye, "Grading of harvested mangoes quality and maturity based on machine learning techniques," in *2018 International Conference on Smart City and Emerging Technology (ICSCET)*, pp. 1–6, Jan 2018.

[67] T. K. Hariadi, H. Zidni, K. T. Putra, and S. Riyadi, "High accuracy real time machine vision for diameter measurement using simpson algorithm," in *2018 International Conference on Information and Communication Technology Convergence (ICTC)*, pp. 625–629, Oct 2018.

[68] J. N. B. Capucao and T. D. Palaoag, "Detecting ripe canarium ovatum (pili) using adaboost classifier and color analysis," in *2018 IEEE International Conference on Computer and Communication Engineering Technology (CCET)*, pp. 315–319, Aug 2018.

[69] A. A. Chandini and U. M. B, "Improved quality detection technique for fruits using glcm and multiclass svm," in *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 150–155, Sep. 2018.

[70] X. Liu, S. W. Chen, S. Aditya, N. Sivakumar, S. Dcunha, C. Qu, C. J. Taylor, J. Das, and V. Kumar, "Robust fruit counting: Combining deep learning, tracking, and structure from motion," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 1045–1052, Oct 2018.

[71] N. Häni, P. Roy, and V. Isler, "Apple counting using convolutional neural networks," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 2559–2565, Oct 2018.

[72] M. K. Monir Rabby, B. Chowdhury, and J. H. Kim, "A modified canny edge detection algorithm for fruit detection classification," in *2018 10th International Conference on Electrical and Computer Engineering (ICECE)*, pp. 237–240, Dec 2018.

[73] S. S. Deulkar and S. S. Barve, "An automated tomato quality grading using clustering based support vector machine," in *2018 3rd International Conference on Communication and Electronics Systems (ICCES)*, pp. 1128–1133, Oct 2018.

[74] V. Casey, "Developing trust in virtual software development teams," *Journal of Theoretical and Applied Electronic Commerce Research*, vol. 5, no. 2, pp. 41–58, 2010.

[75] S. Lu, Z. Lu, P. Phillips, S. Wang, J. Wu, and Y. Zhang, "Fruit classification by hpa-slfn," in *2016 8th International Conference on Wireless Communications Signal Processing (WCSP)*, pp. 1–5, Oct 2016.

[76] E. D. S. Mulyani and J. P. Susanto, "Classification of maturity level of fuji apple fruit with fuzzy logic method," in *2017 5th International Conference on Cyber and IT Service Management (CITSM)*, pp. 1–4, Aug 2017.

[77] G. Zeng, "Fruit and vegetables classification system using image saliency and convolutional neural network," in *2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference (ITOEC)*, pp. 613–617, Oct 2017.

[78] S. W. Sidehabi, A. Suyuti, I. S. Areni, and I. Nurtanio, "Classification on passion fruit's ripeness using k-means clustering and artificial neural network," in *2018 International Conference on Information and Communications Technology (ICOIACT)*, pp. 304–309, March 2018.

[79] L. F. S. Pereira, S. Barbon Jr, N. A. Valous, and D. F. Barbin, "Predicting the ripening of papaya fruit with digital imaging and random forests," *Computers and Electronics in Agriculture*, vol. 145, pp. 76–82, 2018.

[80] S. Mim, G. Smd, H. Fmd, and A. Jerin, "Digital measurement of maturity indices of mangoes using selected image features," *cientia Horticulturae*, pp. 156–163, 2018.

[81] M. T. Habib, A. Majumder, A. Jakaria, M. Akter, M. S. Uddin, and F. Ahmed, "Machine vision based papaya disease recognition," *Journal of King Saud University-Computer and Information Sciences*, 2018.

[82] Y. A. Akter and M. O. Rahman, "Development of a computer vision based eggplant grading system," in *Proc. 4th Int. Conf. Advances in Electrical Engineering (ICAEE)*, pp. 285–290, Sept. 2017.

[83] S. Naik and B. Patel, "Thermal imaging with fuzzy classifier for maturity and size based non-destructive mango (mangifera indica l.) grading," in *Proc. Int. Conf. Emerging Trends Innovation in ICT (ICEI)*, pp. 15–20, Feb. 2017.

[84] C. S. Nandi, B. Tudu, and C. Koley, "A machine vision technique for grading of harvested mangoes based on maturity and quality," *IEEE sensors Journal*, vol. 16, no. 16, pp. 6387–6396, 2016.