

RECYT

Año 22 / N° 34 / 2020 / 67-76

Clasificación Automática de Limón Sutil Peruano (Citrus Aurantifolia) usando Máquinas de Vectores de Soporte

Automatic Sorting of Peruvian Subtle Lemon (Citrus Aurantifolia) using Support Vector Machines

Freddy Alcarazo-Ibáñez¹, Víctor Tuesta-Monteza¹, Heber Iván Mejía-Cabrera¹, Juan Carlos Callejas¹, Raciél Yera²

1- Universidad Señor de Sipán. Carretera a Pimentel Km. 5, Chiclayo, Perú

2- Universidad de Ciego de Ávila. Carretera a Morón Km. 9 ½, Ciego de Ávila, Cuba.

*E-mail: callejas1959@yahoo.es

Recibido: 20/02/2020; Aprobado: 26/10/2020

Resumen

La clasificación manual de frutas es un proceso que requiere de personal experto y es propenso al error humano. Reviste entonces vital importancia la automatización del mismo utilizando herramientas computacionales. En esta investigación se propuso un marco de trabajo basado en la aplicación de técnicas de Pre-Procesamiento de Imágenes y de Visión Artificial para clasificar de manera automática frutos del Limón Sutil Peruano (Citrus Aurantifolia) por color. Se presenta un prototipo de clasificación soportado por una plataforma de hardware para extraer las características de Momentos de Color de las imágenes de Citrus Aurantifolia con vistas a entrenar las técnicas de clasificación de Máquina de Vectores de Soporte (SVM) y K-Vecinos más Cercanos (KNN). Los resultados arrojaron que utilizando el Momento de Color de la media del canal R (rojo), SVM obtuvo una precisión del 98%. Al convertir las imágenes al espacio de color CIELAB utilizando las coordenadas a^* y b^* la precisión obtenida por las técnicas SVM y K-NN fue del 100%.

Palabras clave: Clasificación automática, Limón Sutil Peruano, Máquinas de Vectores de Soporte, K-Vecinos más Cercanos, pre-procesamiento de imágenes.

Abstract

The manual classification of fruits is a process that requires expert knowledge and is prone to human error. Therefore, the automation of such process through the use of computational tools is of high importance. This research proposes a framework based on the application of image pre-processing techniques and artificial vision for automatically classifying Citrus Aurantifolia fruits through their colors. A classification prototype is presented which is supported by a hardware platform to extract the Color Moments features from the Citrus Aurantifolia images, so as to train the Support Vector Machine (SVM) and K-nearest neighbors (KNN) classification techniques. Results conclude that using the Color Moment related to the mean of the R channel, SVM reaches a precision of 98%. When images were converted into the CIELAB color space, the use of the coordinates a^* and b^* leads to a precision of 100% using the classifiers SVM and KNN.

Keywords: Automatic classification, subtle Peruvian lemon, support vector machine, K-nearest neighbors, image pre-processing.

Introducción

Diversos mercados del mundo importan el Limón Sutil Peruano (Citrus Aurantifolia), el cual es fuente importante de vitamina C para las personas, siendo esto recomendado por la Organización Mundial de la Salud (OMS) [1].

Un proceso importante con vistas a su comercialización resulta la clasificación manual de este limón, en maduro, pintón, o verde. Sin embargo, por ser un proceso manual existe una alta probabilidad de que se realicen clasifi-

caciones incorrectas debido al factor del error humano, convirtiéndose así al proceso en impreciso al depender de factores subjetivos como es el estado de salud de la persona y la experticia de la misma. A raíz de lo anterior, la presente contribución se centra en el uso de herramientas computacionales que automaticen esta clasificación, contribuyendo así a mitigar estas insuficiencias.

La revisión del estado del arte en esta línea de investigación permite identificar varios antecedentes de trabajos relacionados con la clasificación automática de cítricos

usando técnicas computacionales. En esta dirección, Ying et al. [2] proponen un método para evaluar el estado de madurez de los cítricos basándose en rasgos de color, evaluando la propuesta en una base de datos de 252 imágenes del cítrico de Weizhang. En adición, Khojastehnazhand et al. [3] propuso una arquitectura compuesta por varios componentes de hardware como cámaras y tarjetas de captura, con vistas a evaluar la calidad de frutos de limón. Recientemente, Blasco et al. [4] presentan un revisión de los desarrollos tecnológicos más actuales centrados en evaluar la calidad de las frutas de diversos cítricos, considerando determinación de defectos, forma y color. En este sentido a pesar de ser un área de trabajo abordada previamente por algunos autores, existen aún muy pocos trabajos centrados en mostrar un estudio completo de la evaluación de la calidad de imágenes de cítricos usando una base de datos real, tal y como ha sido recientemente evidenciado por Bhargava et al [5].

Con vistas a cubrir esta brecha, el objetivo de este trabajo es el de reportar la experiencia del desarrollo de un marco de trabajo basado en hardware y software, para la clasificación automática de Citrus Aurantifolia en la región de Lambayeque, Perú, basado en técnicas de aprendizaje automático y visión artificial.

Para la clasificación automática de Citrus Aurantifolia se utiliza la técnica de Máquina de Vectores de Soporte (SVM) y K-Vecinos más Cercanos (KNN) [6] utilizando las características de Momentos de Color [7]. Estas permiten aplicar operaciones estadísticas tales como la media, desviación estándar, asimetría o curtosis sobre los canales de las imágenes de las clases Maduro, Pintón y Verde de Citrus Aurantifolia en el espacio de color RGB, y permiten la identificación de las mismas. Además, las imágenes originales de Citrus Aurantifolia fueron convertidas a otros espacios de color con la finalidad de mejorar los resultados. Un prototipo de clasificación automática de Citrus Aurantifolia fue desarrollado para probar el sistema de clasificación en un ambiente real.

La novedad del trabajo se puede resumir en:

- La utilización de técnicas de inteligencia artificial y de visión por computadora en la clasificación de frutas de Citrus Aurantifolia.
- El desarrollo de un prototipo de clasificación automática para probar el sistema de clasificación.
- La evaluación de las propuestas en un escenario con casos reales.

El trabajo se estructura de la forma siguiente. La sección II muestra los antecedentes más directos de la presente investigación, a partir de los trabajos relacionados. La sección III muestra el desarrollo de la propuesta, mientras que la sección IV muestra los resultados del estudio realizado sobre datos reales. La sección V muestra las conclusiones y los posibles trabajos futuros a desarrollar.

II. Trabajos Relacionados

El problema de la identificación manual de frutas por su estado de maduración, siempre ha presentado variabilidad e imprecisión por factores subjetivos como la fatiga ocular del experto clasificador, o el estado de salud general de la persona [5, 8]. A pesar de ser esta un área de trabajo también abordada previamente desde el punto de vista computacional por varios investigadores [5], existe un número menor de trabajos enfocados específicamente en el dominio de los cítricos.

En esta dirección, Ying et al. [2] proponen un método para evaluar el estado de madurez de los cítricos basándose en rasgos de color. Con este fin, utilizan una red neuronal de tres capas del tipo *feed-forward* para mapear las características del cítrico basándose en sus niveles de color. Esto es evaluado en una base de datos de 252 imágenes de cítricos provenientes de la región de Weizhang, China. Por otro lado, Khojastehnazhand et al. [3] proponen una arquitectura compuesta por varios componentes de hardware como cámaras y tarjetas de captura, con vistas a evaluar la calidad de frutos de limón. En este caso utilizan los valores de saturación e intensidad como rasgos determinantes, así como el volumen de la fruta. La calibración del sistema es hecha tomando como referencia muestras previas de tipos de frutas, elegidas por expertos. En adición, Posada et al. [9] han presentado un sistema de parametrización y clasificación automática de limones persas, en el que evalúan las variaciones morfométricas y colorímetras a través de datos estadísticos de posicionamiento en el canal RGB de una imagen. Asimismo, Dorj et al. [6] proponen un algoritmo que utiliza los rasgos de color para presentar una visión global de las características del cítrico, empleando la segmentación basada en la transformada *watershed*. Finalmente, Vidal et al. [7] proponen la estimación del índice estándar de color del cítrico usando un sistema desarrollado para una plataforma móvil.

Resumiendo, el análisis de los trabajos previos sugiere la presencia de una cantidad menor de investigaciones relacionadas con el uso de herramientas computacionales para apoyar la caracterización manual de cítricos, en comparación con otras frutas y vegetales [5, 8, 9].

El presente trabajo se centra en esta dirección, al proponer un marco de trabajo para la clasificación automática de Citrus Aurantifolia en la región de Lambayeque, Perú, basado en técnicas de aprendizaje automático y visión artificial.

Desarrollo de la Propuesta

El marco de trabajo propuesto para llevar a cabo la clasificación automática de Citrus Aurantifolia por color se presenta en la Figura 1. A continuación se describen cada una de las etapas de este marco de trabajo.

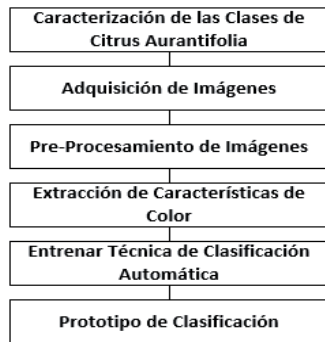


Figura 1: Marco de trabajo propuesto para la Clasificación Automática de Citrus Aurantifolia por Color.

A. Caracterización de las Clases de Citrus Aurantifolia

Para realizar la recolección de las muestras de Citrus Aurantifolia se recurrió a un experto en agroindustria el cual pudo proporcionar las características de color de cada una de las clases de Citrus Aurantifolia (Maduro, Pintón y Verde) en una matriz con el color promedio en RGB de las clases.




Figura 2: Clases Verde, Pintón y Maduro de Citrus Aurantifolia.

Con base a las características de color adquiridas por el experto se recolectaron las muestras. En la Figura. 2 se puede apreciar de izquierda a derecha la clase Verde, Pintón y Maduro de Citrus Aurantifolia. La clase “Verde”

se caracteriza por tener un color de textura de verde oscuro, la clase “Pintón” tiene un color de textura verde con manchas amarillas y en la mayoría de los casos su color es menos oscuro que la clase “Verde”. La clase “Maduro” se caracteriza por tener toda la textura amarilla con ligeros tonos de color verde.

B. Adquisición de Imágenes

Se obtuvo una base de datos de 350 imágenes por cada clase de Citrus Aurantifolia en el espacio de color RGB. Las imágenes se adquirieron utilizando un prototipo de adquisición de imágenes con iluminación controlada como se aprecia en la Figura 3. Se utilizó la fuente de iluminación LED (6w, 500 lúmenes, 180-240v), la cual es una fuente de iluminación económica, de respuesta rápida y menos sensible a vibraciones, que proporciona una intensidad de luz moderada y difusa.

La cámara utilizada en el prototipo de adquisición de imágenes (Figura 4) tuvo una resolución de 5 Megapíxeles (Mpx) de marca Logitech (modelo C-170). Las imágenes adquiridas tuvieron una resolución de 640x480 Mpx en el espacio RGB.

Un programa escrito en el lenguaje de programación Python utilizando la librería de código abierto OpenCV permitió acceder a la cámara Logitech C-170 para adquirir las imágenes de Citrus Aurantifolia.

Todas las imágenes fueron separadas en carpetas, es decir se agruparon en distintas carpetas aquellas clases que pertenecen a la clase “Maduro”, “Pintón” y “Verde”. Por lo tanto, se obtuvo una base de datos de 1050 imágenes correctamente ordenadas para posteriormente realizar su pre-procesamiento. En la Figura 5 podemos apreciar imágenes de ejemplo que fueron adquiridas mediante el prototipo de adquisición de imágenes.




Figura 3: Diseño 3D del Prototipo de Adquisición de Imágenes de Citrus Aurantifolia.



Figura 4: Imágenes Reales del Prototipo de Adquisición de Imágenes de Citrus Aurantifolia.

C. Pre-Procesamiento de las Imágenes

Una vez elaborada la base de datos de imágenes de Citrus Aurantifolia con las clases Maduro, Pintón y Verde,

se procede a realizar el pre-procesamiento de las imágenes. Esto se realiza con la finalidad de lograr su segmentación y elaborar una nueva base de datos de imágenes segmentadas de las tres clases de Citrus Aurantifolia, para posteriormente utilizar dicha base de datos y extraer las características de color de cada una de las imágenes.

El primer paso fue aplicar la corrección gamma, según [10] la corrección gamma se utiliza para corregir el brillo de una imagen utilizando una transformación no lineal entre los valores de entrada y los valores de salida asignados (Ecuación 1).

$$O = I^{(1/G)} \quad (1)$$

Donde I es la imagen de entrada, G es el valor gamma, en este caso particular se utilizó $G = 0.8$, y O es la imagen de salida escalada en un rango de $[0, 255]$.

Posteriormente a las imágenes se les aplico un filtro pasa bajo “blur” para atenuar las frecuencias altas y dejar invariantes las frecuencias bajas. Filtrada la imagen con el filtro pasa bajo se convirtió al espacio de color HSV, según [11] el espacio de color HSV tiene la ventaja de ser invariante a las condiciones de luz y por lo tanto la conversión a HSV se realiza para detectar la presencia de Citrus Aurantifolia en las imágenes adquiridas respecto

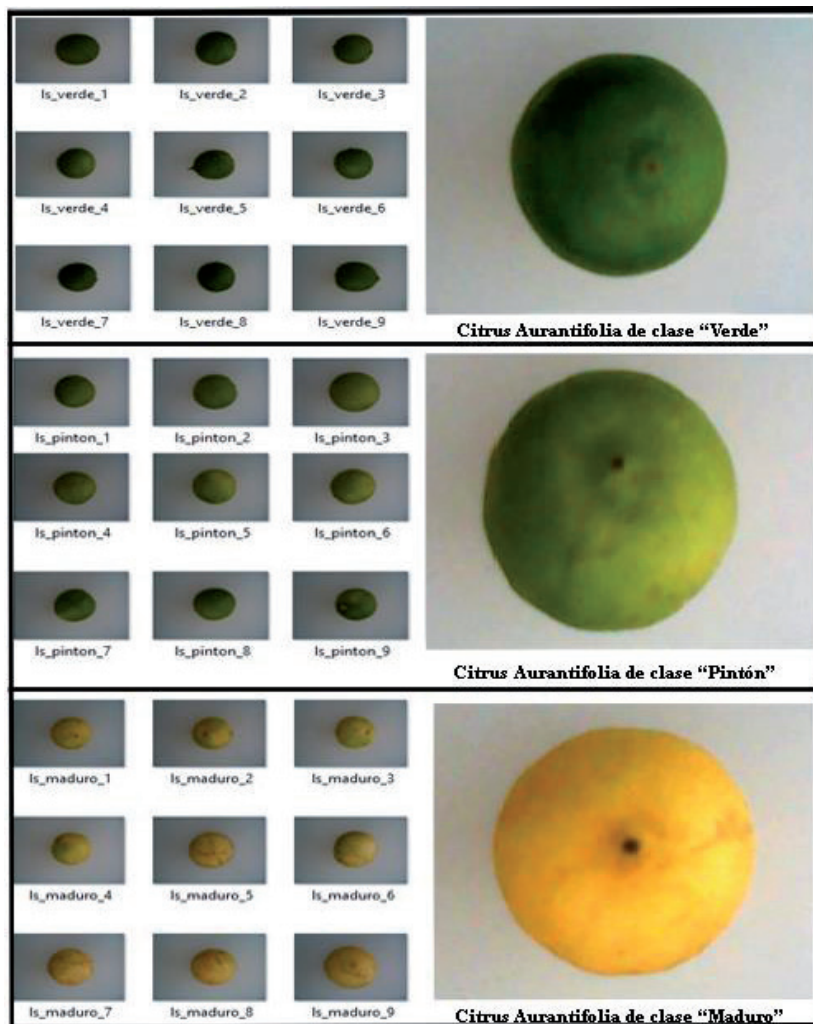


Figura 5: Imágenes Adquiridas de Citrus Aurantifolia.

a su fondo. El siguiente paso fue convertir la imagen en HSV a escala de grises para poder aplicar el método de segmentación Otsu [12] para encontrar un nivel de umbral en las imágenes de Citrus Aurantifolia las cuales tiene un fondo de color blanco (Figura 4).

Las técnicas aplicadas para realizar el pre-procesamiento de las imágenes de Citrus Aurantifolia se resumen en la Figura 6.

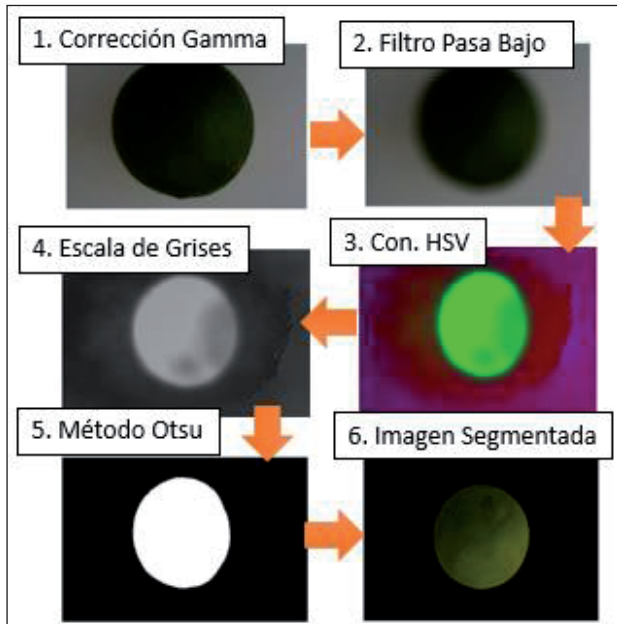


Figura 6: Etapas del Pre-procesamiento de las Imágenes de Citrus Aurantifolia.

D. Extracción de Características de Color

El color es considerado una característica importante para la representación de una imagen debido a que dicho atributo es invariante con respecto a la escala y rotación

de esta. Los momentos de color utilizados para describir las imágenes son la varianza de color, la media de color, la curtosis de color y la asimetría de color [7]. Según [13] los momentos de color se basan en el supuesto de que la distribución del color en una imagen puede ser interpretada como una distribución de probabilidad. Las distribuciones de probabilidad se caracterizan por un número de momentos; por ejemplo, las distribuciones normales se diferencian por su media y varianza. Por lo tanto, se deduce que si el color de una imagen sigue una cierta distribución de probabilidad, los momentos de esa distribución pueden ser utilizados como características para identificar una imagen basándose en el análisis de su color [13]. Se extrajeron las características de color de la media del canal R (Rojo) de las imágenes de Citrus Aurantifolia. Se omitieron las características de la media de canal Verde (Green) y Azul (Blue) debido a que no presentaron valores diferenciadores que pudieran servir para entrenar una técnica de clasificación automático.

En la Figura 7 se puede apreciar que los valores de la media del canal R (rojo) tienden a disminuir. En esta dirección, los valores más altos del canal R los tiene la clase “Maduro” de Citrus Aurantifolia, seguidamente los valores menores del canal R los tiene la clase “Pintón”, y finalmente la clase “Verde” es aquella clase que tiene los valores más bajos del canal R.

Por lo tanto las características de la media del canal Rojo se extrajeron mediante la siguiente ecuación:

$$Media_R = R/N \tag{2}$$

Donde R es el canal Rojo de las imágenes de Citrus Aurantifolia y N es el número total de píxeles.

Con el objetivo de mejorar los resultados se obtienen los valores promedios de las coordenadas a* y *b (relación a*/b*) del espacio de color CIELAB. El espacio de color

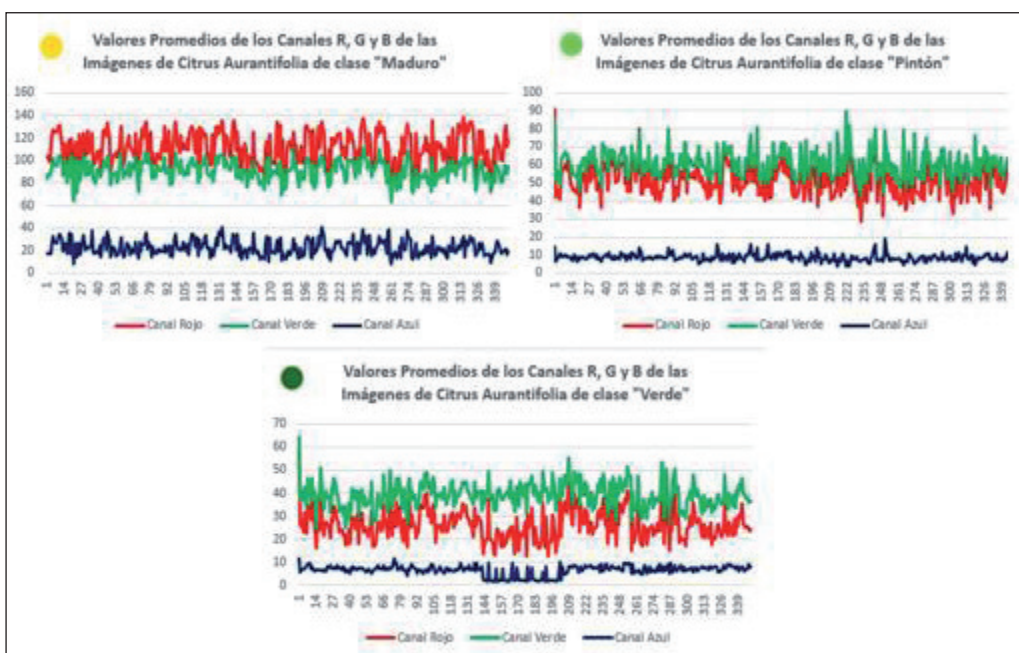


Figura 7: Media del Canal R (Rojo) de las Imágenes de Citrus Aurantifolia.

CIE L* a* b* es muy utilizado debido a la uniformidad en la distribución de colores en el dicho espacio [14]. En [15] se estudió la evolución del color de epicarpis de tomates durante 27 días, se determinó que las coordenadas a* y b* del espacio de color CIELAB presentan valores bajos cuando el estado de maduración del tomate es verde y valores más altos cuando el tomate tiene un mayor nivel de madurez. A raíz de lo anterior, la relación de las coordenadas a*/b* son extraídas para mejorar la precisión de la clasificación de las clases de Citrus Aurantifolia.

Para extraer las características de la relación a*/b* se utiliza una base de datos de 250 imágenes por clase. Estas imágenes de la nueva base de datos fueron extraídas de la base de datos original de 350 imágenes por clase. Partiéndose de esta, se realizó un análisis para separar aquellas imágenes de Citrus Aurantifolia que presentaban características distintivas, con la finalidad de obtener una mayor capacidad de aprendizaje por parte de la técnica de clasificación utilizada posteriormente.

En la Figura 8 se puede apreciar la representación gráfica de las características extraídas de la relación a*/b* de las imágenes de Citrus Aurantifolia en el espacio de color CIELAB. Este tipo de gráfico permite verificar si las características presentan o no demasiado ruido y si no están muy mezcladas, lo cual incidiría de forma negativa en la utilización de la técnica de clasificación.




Figura 8: Representación gráfica de las Características de la relación a*/b* extraídas de las imágenes de Citrus Aurantifolia en el espacio de Color CIELAB.

La representación gráfica de las características de la relación a*/b* de las imágenes de Citrus Aurantifolia en el espacio de color CIELAB mostradas en la Figura 8 permiten concluir que las características de la clase Maduro presentan los valores más altos, mientras que los valores más bajos los tiene la clase Verde. Más específicamente, en el orden de mayor a menor la clase Maduro tiene los valores más altos, la clase Pintón presenta valores más bajos que la clase Maduro y la clase Verde tiene los valores más bajos de todas las clases.

En la Tabla 1 se muestran los valores de las nueve primeras características extraídas de ejemplo de cada clase (Maduro, Pintón y Verde) de Citrus Aurantifolia.

Por lo tanto, a partir de las características extraídas de ejemplo de Citrus Aurantifolia que se aprecian en la Tabla 1 se corrobora lo indicado por [15], pudiéndose apreciar valores altos para Citrus Aurantifolia de clase “Maduro”

y “Pintón” mientras que los valores más bajos los tiene la clase “Verde”. Por lo tanto valores bajos de las características extraídas de la relación a*/b* representan la presencia de color verde en Citrus Aurantifolia y valores más altos representan la presencia de color amarillo [15], o mayor estado de madurez en Citrus Aurantifolia.

Tabla 1: Características de ejemplo de la relación a*/b* de las imágenes de Citrus Aurantifolia.

Maduro	Pintón	Verde
21.18	6.60	3.52
21.53	6.72	2.44
24.00	4.76	2.85
23.72	8.59	2.14
23.13	9.84	4.17
24.54	10.03	3.83
24.97	9.97	4.87
24.87	10.10	3.40
23.68	11.92	3.22

E. Entrenar Técnica de Clasificación Automática

Se eligió utilizar las técnicas de clasificación automática de Máquinas de Vectores de Soporte (SVM) y K-Vecinos más Cercanos (KNN) para clasificar las instancias capturadas de Citrus Aurantifolia en las clases maduro, pintón o verde. En trabajos previos como el desarrollado por Hamed et al. [6] se realizó una comparación de diversas técnicas de clasificación automática aplicadas a la clasificación de frutas y vegetales, y en estas técnicas se destacan por haber obtenido una mayor tasa de precisión frente a otras técnicas aplicadas en la clasificación de frutas como son Redes Neuronales Artificiales (ANN), K-medias, Naive Bayes entre otras.

La técnica de clasificación SVM está conformada por un clasificador binario que se usa ampliamente para la clasificación de datos en muchas aplicaciones, siguiendo un procedimiento para encontrar un hiperplano de separación óptimo [8]. Esta técnica, con datos no lineales, asigna el espacio de entrada original de las características a un espacio de entidades de mayor dimensión. Dicho mapeo maximiza las capacidades de generalización del clasificador utilizando funciones *kernel* las cuales son capaces de poder ampliar la separación entre las clases [8].

Dado un conjunto de ejemplos de entrenamiento $\{(X_i, lab_i) : i = 1, 2, \dots, n\}$ donde X_i es el vector de características, y $lab_i \in [-1, +1]$ son las etiquetas o clases de las muestras de entrenamiento, el límite óptimo está definido como:

$$f(x) = w * x + b \quad (3)$$

Donde w y b pueden ser resueltos siguiendo el problema de optimización siguiente:

$$\text{Minimizar } \frac{1}{2} \|w\|^2 + C \sum_i e_i \quad (4)$$

Donde C es el parámetro de penalidad ($C > 0$) y ϵ es

el valor del error, sujeto además a la siguiente restricción $lab_i(w * x_i + b) \geq 1 - \epsilon_i, i = 1, 2, \dots, n$. La solución de este problema de optimización maximiza el margen de la frontera de decisión.

Se utilizó una función kernel de base radial (RBF) debido a que las características de Citrus Aurantifolia no son linealmente separables. La función de base radial ofrece buenos resultados en muchas aplicaciones de clasificación automática con SVM en datos linealmente no separables [8]. Por lo tanto, la ecuación presente en la expresión (3) se convierte en:

$$f(x) = \sum_{i \in \Omega} \alpha_i (lab_i(\exp(\gamma \|x - x_i\|^2))) \quad (5)$$

Donde α_i es el coeficiente de Lagrange, Ω es el conjunto de índices diferentes de cero de α_i , γ es un parámetro libre, X es un ejemplo de prueba, y $\|\cdot\|^2$ es la distancia euclídea.

El método propuesto de esta investigación se centra en clasificar las clases Maduro, Pintón y Verde de Citrus Aurantifolia. Considerando que no se tienen dos clases binarias y se tienen más de dos clases se aplicó la clasificación SVM multiclase [8]. Para su implementación se utilizó la librería SciKitLearn utilizada en aplicaciones de aprendizaje automático la cual es de código abierto y se utiliza en el lenguaje de programación Python.

Por otra parte la técnica de clasificación automática K-NN se basa en clasificar puntos de datos desconocidos utilizando la distancia euclídea. Cada punto de datos en los k puntos de datos más cercanos emite el voto y la categoría con el mayor número de votos gana [16].

Ambas técnicas de clasificación SVM y KNN se entrenaron con el 80% de las características de Citrus Aurantifolia y se reservó el 20% para realizar las pruebas de clasificación. El rendimiento de ambas técnicas de cla-

sificación se evaluó obteniendo una matriz de confusión, la cual según [17] permite evaluar el desempeño de técnicas o modelos de clasificación automático obteniendo una serie de medidas que se presentarán en la sección de resultados.

F. Prototipo de Clasificación Automático de Citrus Aurantifolia

El prototipo de clasificación automática implementado en esta investigación tiene una faja transportadora la cual se adaptó al prototipo de adquisición de imágenes (Figura 4). La faja transportadora es controlada mediante un microcontrolador Arduino y un driver L298 (Puente H). Se utiliza un sensor infrarrojo para detectar Citrus Aurantifolia antes de llegar a la cámara. Detectado el fruto por el sensor, la faja transportadora es detenida por 5 segundos, tiempo que se utiliza para que el sistema adquiera los datos, en este caso la imagen de Citrus Aurantifolia y seguidamente extraiga las características del fruto. Finalizada los 5 segundos de espera se envía el comando “t” para que el sistema de clasificación en la computadora proceda a clasificar el fruto con las características de la imagen capturada, de la misma manera se hace una pausa de 2 segundos para enviar el comando al computador.

Terminado el tiempo la faja transportadora se inicia y el microcontrolador Arduino queda en espera que le llegue el número de la clase predicha por el clasificador. El valor enviado al microcontrolador es capturado para procesarlo por tres condiciones las cuales verifican si el valor recibido desde el computador corresponde a la clase maduro (0), pintón (1) o verde (2), y en función de dichos valores se mueven los actuadores luego de un determinado tiempo. En las Figuras 9 y 10 se aprecian imágenes reales del prototipo de clasificación automática de Citrus Aurantifolia por color.




Figura 9: Partes del Prototipo de Clasificación Automático de Citrus Aurantifolia.

A modo de resumen, en la Figura 11 se aprecia respectivamente el diagrama de flujo que se desarrolla entre el prototipo de clasificación automática de Citrus Aurantifolia y la computadora la cual contiene en ejecución la técnica de clasificación automática SVM.




Figura 10: Prototipo de Clasificación Automático de Citrus Aurantifolia.

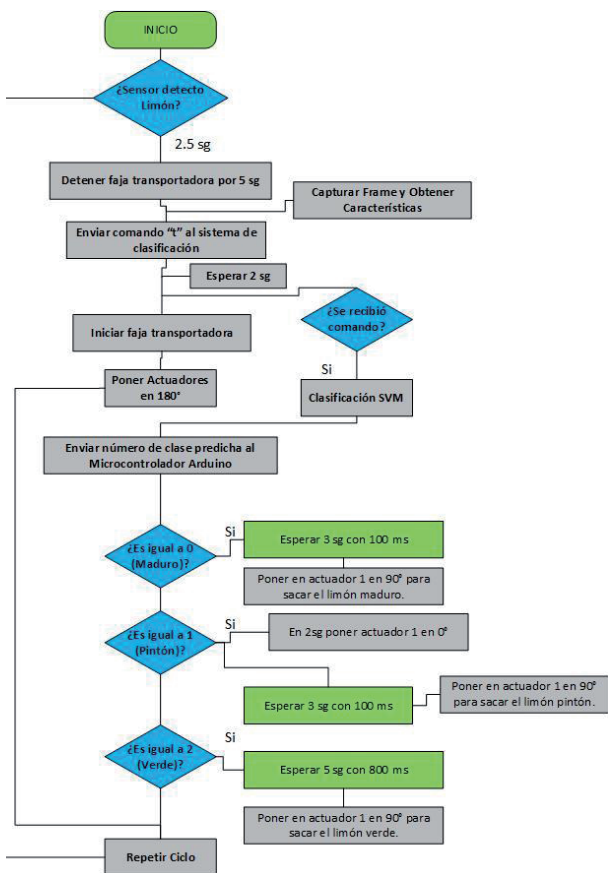


Figura 11: Diagrama de Flujo del Prototipo de Clasificación Automático de Citrus Aurantifolia.

Resultados

A continuación, se presentan los resultados obtenidos de la clasificación automática de Citrus Aurantifolia utilizando las características de los Momentos de Color.

En un primer momento, la técnica de clasificación automática SVM fue entrenada con las características de la media del canal R (rojo) de las imágenes de Citrus Aurantifolia en el espacio de color RGB.

La técnica SVM obtuvo una precisión general del 98%, mientras que se obtuvo una tasa de precisión de 98% para

todas las clases de Citrus Aurantifolia (Maduro, Pintón y Verde). En el mismo orden de clases de Citrus Aurantifolia, la sensibilidad obtenida fue del 100%, 96% y 98% respectivamente. La tasa de especificidad obtenida de las clases fue del 99% y se obtuvo una exactitud del 99% para la clase Maduro, 98% para la clase Pintón, y la clase Verde obtuvo una tasa del 99% respectivamente. La técnica de clasificación SVM obtuvo un tiempo computacional de 0.0467925 seg.

En la Figura 12 se puede apreciar la representación gráfica de los resultados obtenidos de la técnica de clasificación SVM evaluada con los indicadores de sensibilidad, especificidad, exactitud y precisión en clasificar las clases de Citrus Aurantifolia, utilizando las características del Momento de Color de la media del canal R (Rojo) de las imágenes de Citrus Aurantifolia en el espacio de color RGB.




Figura 12: Gráfico de los resultados de la técnica de clasificación SVM entrenada con las características del Momento de Color de la media del canal rojo (R) de las imágenes de Citrus Aurantifolia en el espacio de color RGB.

Estos resultados obtenidos fueron mejorados al entrenar las técnicas de clasificación SVM y KNN con las características de la relación a*/b* de las imágenes de Citrus Aurantifolia en el espacio de color CIELAB. Aquí es de resaltar que ambas técnicas de clasificación SVM y KNN al computar los indicadores obtuvieron una tasa de precisión del 100% en clasificar las clases Maduro, Pintón y Verde.

Sin embargo, los tiempos computacionales de ejecución consumidos por las técnicas de clasificación fueron distintos. La técnica de SVM obtuvo un tiempo computacional de ejecución de 0.029801 segundos (29 milisegundos), mientras que el tiempo computacional consumido por la técnica KNN fue de 0.0074096 segundos, es decir aproximadamente 7 milisegundos. Sin embargo, a pesar de que la técnica KNN obtuvo en este caso un tiempo de ejecución menor respecto a SVM, el procesamiento de KNN a gran escala es computacionalmente costoso y requiere de una gran cantidad de memoria para un cálculo eficiente de las similitudes [18]. Se necesitan análisis adicionales para decidir la mejor técnica a utilizar desde el punto de vista computacional, en un escenario a mayor escala.

Conclusiones y Trabajos Futuros

La presente contribución ha presentado un marco de trabajo para la clasificación automática de Citrus Auranti-

folia, el cual está compuesto por seis etapas fundamentales, que son la Caracterización de las clases, Adquisición de las imágenes, Pre-procesamiento de las imágenes, Extracción de las características del color, Entrenar técnica de clasificación automática, y el Prototipo de clasificación

Se concluyó que las características del espacio de color CIELAB (relación a^*/b^*) han permitido obtener una tasa de precisión del 100% en clasificar las clases Maduro, Verde y Pintón de Citrus Aurantifolia. El resultado obtenido fue superior respecto a la utilización de las características del Momento de Color de la media del canal R (rojo) de las imágenes de Citrus Aurantifolia en el espacio de color RGB para entrenar la técnica de clasificación SVM. En este último caso la técnica obtuvo una tasa de precisión general del 98%.

La técnica de clasificación KNN obtuvo un menor tiempo de ejecución respecto a la técnica de clasificación SVM utilizando las características de la relación a^*/b^* de las imágenes de Citrus Aurantifolia en el espacio de color CIELAB.

Las técnicas de pre-procesamiento digital de imágenes y visión artificial se han utilizado sin inconvenientes y demuestran que pueden obtener una tasa de precisión alta en la clasificación automática de frutas como es Citrus Aurantifolia. Por lo tanto su aplicación para automatizar procesos de clasificación manual de frutas puede ayudar a disminuir los errores cometidos por personal experto en clasificación de frutas. Aunque estos sistemas no pueden igualar la precisión del ojo y la mano de los humanos, la velocidad y el costo al que trabajan pueden superarlas fácilmente.

Como trabajo futuro más inmediato, se propone realizar un análisis completo de la superficie de la fruta utilizando otro diseño de faja transportadora que permita rotar la fruta 360° con la finalidad de detectar la presencia de defectos, forma y tamaño de Citrus Aurantifolia. En adición, se pretende aplicar herramientas provenientes de la lógica difusa con el fin de manejar la incertidumbre asociada al proceso de clasificación [19].

Referencias bibliográficas

1. O. S. Enejoh, I. O. Ogunyemi, M. S. Bala, I. S. Oruene, M. M. Suleiman, and S. F. Ambali, "Ethnomedical importance of *Citrus aurantifolia* (christm) swingle," The Pharma Innovation, vol. 4, p. 1, 2015.
2. Y. Ying, H. Xu, and Z. Xu, "Non--destructive maturity evaluation of citrus by hue frequency sequence method," Journal of Biomathematics, vol. 21, pp. 306-312, 2006.
3. M. Khojastehnazhand, M. Omid, and A. Tabatabaeefer, "Development of a lemon sorting system based on color and size," African Journal of Plant Science, vol. 4, pp. 122-127, 2010.
4. J. Blasco, S. Cubero, and E. Moltó, "Quality evaluation of citrus fruits," in Computer vision technology for food quality evaluation, ed: Elsevier, 2016, pp. 305-325.
5. A. Bhargava and A. Bansal, "Fruits and vegetables quality evaluation using computer vision: A review," Journal of King Saud University-Computer and Information Sciences, 2018.
6. K. Hameed, D. Chai, and A. Rassau, "A comprehensive review of fruit and vegetable classification techniques," Image and Vision Computing, vol. 80, pp. 24-44, 2018.
7. 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, 2014, pp. 164-168.
8. G. Muhammad, "Date fruits classification using texture descriptors and shape-size features," Engineering Applications of Artificial Intelligence, vol. 37, pp. 361-367, 2015.
9. M. Vassallo-Barco, L. Vives-Garnique, V. Tuesta-Monteza, H. I. Mejia-Cabrera, and R. Yera, "Automatic Detection of Nutritional Deficiencies In Coffee Tree Leaves Through Shape And Texture Descriptors," Journal of Digital Information Management, vol. 15, pp. 7-18, 2017.
10. M. B. Atitallah, A. Boudabous, A. B. Atitallah, and R. Kachouri, "Complexity study of the Gamma correction method for text extraction from complex images," in 2015 16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA), 2015, pp. 422-426.
11. N. A. Dobernack, "Implementación de un sistema de detección de señales de tráfico mediante visión artificial basado en FPGA," Universidad de Sevilla, Sevilla, España.[Online] Available: http://bibing.us.es/proyectos/abreproy/12112/fichero/Documento_por_capitulos_vol_2_2013.
12. D. E. Figueroa and E. R. Guerrero, "Sistema de visión artificial para la identificación del estado de madurez de frutas (granadilla)," Redes de Ingeniería, vol. 7, pp. 78-86, 2016.
13. N. Keen, "Color moments," School Of Informatics, University Of Edinburgh, pp. 3-6, 2005.
14. K. L. Yam and S. E. Papadakis, "A simple digital imaging method for measuring and analyzing color of food surfaces," Journal of food engineering, vol. 61, pp. 137-142, 2004.
15. C. A. Padrón Pereira, P. León, G. Marié, A. I. Montes Hernández, and R. A. Oropeza González, "Determinación del color en epicarpio de tomates (*Lycopersicum esculentum* Mill.) con sistema de visión computarizada durante la maduración," Agronomía Costarricense, vol. 36, pp. 97-111, 2012.
16. D. Unay and B. Gosselin, "Automatic defect segmentation of 'Jonagold' apples on multi-spectral images: A comparative study," Postharvest Biology and Technology, vol. 42, pp. 271-279, 2006.
17. J. D. Kelleher, B. Mac Namee, and A. D'arcy, *Fundamentals of machine learning for predictive data analytics: algo-*

rithms, worked examples, and case studies: MIT press, 2015.

18. **J. Olivares, A.-M. Kermarrec, and N. Chiluka**, “*The out-of-core KNN awakens: the light side of computation force on large datasets*,” *Computing*, vol. 101, pp. 19-38, 2019.
19. **R. Yera and L. Martínez**, “*Fuzzy tools in recommender systems: A survey*,” *International Journal of Computational Intelligence Systems*, vol. 10, pp. 776-803, 2017.