

UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA AGRÍCOLA



**DESARROLLO DE UN SISTEMA DE ADQUISICIÓN DE IMÁGENES
DIGITALES ORIENTADAS AL PROCESAMIENTO Y EVALUACIÓN DE
RACIMOS DE UVA DE MESA**

DENIS FERNANDA PALMA PIZARRO

PROYECTO DE TÍTULO
PRESENTADO A LA FACULTAD
DE INGENIERÍA AGRÍCOLA DE
LA UNIVERSIDAD DE
CONCEPCIÓN, PARA OPTAR AL
TÍTULO DE INGENIERO CIVIL
AGRÍCOLA.

CHILLÁN-CHILE

2023

**DESARROLLO DE UN SISTEMA DE ADQUISICIÓN DE IMÁGENES DIGITALES
ORIENTADAS AL PROCESAMIENTO Y EVALUACIÓN DE RACIMOS DE UVA DE
MESA**

Aprobado por:

Christian Correa Farias
Ingeniero Civil Agrícola, Dr.
Profesor Asociado

Profesor Guía

Mario Lillo Saavedra
Ingeniero Eléctrico, Dr.
Profesor Titular

Profesor Co-Guía

Wilson Esquivel Flores
Ingeniero Civil Mecánico, Dr.
Profesor Asistente

Profesor Co-Guía

Christian Correa Farias
Ingeniero Civil Agrícola, Dr.
Profesor Asociado

Director de Departamento

María Eugenia Gonzales
Ingeniero Agrónomo Ph.D.
Profesor Asociado

Decana

ÍNDICE DE MATERIAS

RESUMEN	9
ABSTRACT	11
1. INTRODUCCIÓN	12
2. HIPÓTESIS	15
3. OBJETIVOS	15
3.1. Objetivo general	15
3.2. Objetivos específicos	15
4. ANTECEDENTES GENERALES	16
4.1. Visión por computadora	16
4.2. Algoritmos de Agrupamiento	17
5. METODOLOGÍA	19
5.1. Adquisición de imágenes	19
5.2. Selección de canales y Espacio de color	20
5.3. Extracción de característica con software	21
5.3.1. Ajuste de contraste	21
5.3.2. Segmentar	21
5.3.3. Relleno imagen resultante	22
5.3.4. Extracción de características	22
5.4. Generación conjunto de datos	23
6. RESULTADOS	24
6.1. Adquisición de imágenes	24
6.2. Selección de canales y Espacio de color	25
6.3. Filtrar	28
6.4. Métodos de agrupamiento por color	29
6.4.1. K-Means	29
6.4.2. Fuzzy C-Means	30
6.5. Segmentación de color	31
6.6. Extracción de características	33
6.7. Conjunto de datos	36
7. CONCLUSIÓN	49
8. LITERATURA CITADA	51

ÍNDICE DE TABLAS

Tabla 1.-Variables medidas a los racimos de estudio de manera manual como el peso, largo del racimo, número de bayas del racimo, y calibre del racimo correspondiendo 900 a bayas sobre los 19 mm y 700 bayas desde los 17,5 mm a los 18,9 mm. _____ 36

Tabla 2.-Variables medidas a los racimos de prueba en de manera manual como el peso, largo del racimo, número de bayas del racimo, y calibre del racimo correspondiendo 900 a bayas sobre los 19 mm y 700 bayas desde los 17,5 mm a los 18,9 mm. _____ 37

Tabla 3.-Variables obtenidas con datos de entrenamiento, con programa utilizando el algoritmo de agrupación K-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real. _____ 38

Tabla 4.-Variables obtenidas con datos de entrenamiento, con programa utilizando el algoritmo de agrupación Fuzzy C-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de acierto según el real. _____ 39

Tabla 5.- Variables obtenidas con datos de prueba, con programa utilizando el algoritmo de agrupación K-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real. _____ 46

Tabla 6.- Variables obtenidas con datos de prueba, con programa utilizando el algoritmo de agrupación Fuzzy C-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real. _____ 46

ÍNDICE DE FIGURAS

Figura 1. Caja de madera con un soporte para el racimo e iluminación con panel led, luz cálida. (Elaboración propia). _____ 20

Figura 2. Imagen con problemas en las paredes interiores y sombra generada por el racimo, obtenida desde la adquisición de imágenes. (Elaboración propia). _____ 25

Figura 3. Imagen de un un racimo de uva de mesa en el espacio de color RGB y sus canales. (Elaboración propia). _____ 25

Figura 4. Imagen de un racimo de uva de mesa en el espacio de color $L^* a^* b^*$ y sus canales. (Elaboración propia). _____ 26

Figura 5. Imagen de un racimo de uva de mesa en el espacio de color HSV y sus canales. (Elaboración propia). _____ 26

Figura 6. Imagen de un racimo de uva de mesa en el espacio de color Ycbcr y sus canales. (Elaboración propia). _____ 27

Figura 7. Imagen de un racimo de uva de mesa en el espacio de color $L^*C^*h^*$ y sus canales. (Elaboración propia). _____ 27

Figura 8. Efecto de realzar una imagen. Se puede notar que la imagen de la derecha está más clara que la de la izquierda, por lo que los bordes de los objetos contenidos pueden ser identificados de mejor modo. (Elaboración propia). _____ 28

Figura 9. Resultado de la clasificación usando K-Means, en Matlab, con dos grupos sobre el espacio de color $L^*c^*h^*$. A la derecha el clúster que contiene el racimo o la información de interés y a la izquierda clúster 1 enmascarado con la imagen original. (Elaboración propia). _____ 29

Figura 10. Resultado de la clasificación aplicando Fuzzy C-Means, sobre el cluster 1 para separar fondo de racimo. A la izquierda, el clúster que contiene el racimo o información de interés enmascarada a partir de la imagen original y a la derecha el clúster resultante de la clasificación. (Elaboración propia). 30

Figura 11. Clúster con elementos de interés limpios (bayas), raquis y sombra eliminadas. (Elaboración propia). _____ 31

Figura 12. Clúster con sombra en la base del raquis, producto de problemas no resueltos por la segmentación. Aparece en tonos gris claro. (Elaboración propia). _____ 32

Figura 13. Resultado de la detección de círculos en las doce imágenes de un racimo. Búsquedas de círculos con un radio entre 70 y 140 píxeles, sin tolerancia para incluir círculos concéntricos. (Elaboración propia). _____ 35

Figura 14. Relación del número de bayas real con el número de círculos detectados utilizando findcircles sobre las imágenes generadas mediante agrupación por K-means. (Elaboración propia).	40
Figura 15. Relación del número de bayas real con el número de círculos detectados utilizando findcircles sobre las imágenes generadas mediante agrupación por Fuzzy C-means. (Elaboración propia).	40
Figura 16. Relación del peso del racimo con el número de bayas obtenidas de la ecuación de regresión lineal de la Figura 14. (Elaboración propia).	41
Figura 17. Relación del peso del racimo con el número de bayas obtenidas de la ecuación de regresión lineal de la Figura 15. (Elaboración propia).	42
Figura 18. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación K-means, solo con racimos de calibre 700. (Elaboración propia).	43
Figura 19. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación K-means, solo con racimos de calibre 900. (Elaboración propia).	43
Figura 20. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación Fuzzy C-means, solo con racimos de calibre 700. (Elaboración propia).	44

Figura 21. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación Fuzzy C-means, solo con racimos de calibre 900. (Elaboración propia). _____ 44

Figura 22. Relación del peso del racimo con el área en pixeles utilizando el algoritmo de agrupación K-means. (Elaboración propia). _____ 45

Figura 23. Relación del peso del racimo con el área en pixeles utilizando el algoritmo de agrupación Fuzzy C-means. (Elaboración propia)._____ 45

DESARROLLO DE UN SISTEMA DE ADQUISICIÓN DE IMÁGENES DIGITALES ORIENTADAS AL PROCESAMIENTO Y EVALUACIÓN DE RACIMOS DE UVA DE MESA.

DEVELOPMENT OF A DIGITAL IMAGES ACQUISITION SYSTEM ORIENTED TO THE PROCESSING AND EVALUATION OF TABLE GRAPE CLUSTERS.

Palabras claves: algoritmos de agrupamiento, adquisición de imágenes, uva de mesa.

RESUMEN

El monitoreo constante de los viñedos, especialmente de los atributos relacionados con la calidad, son sustanciales para asegurar una buena producción. En particular, determinar el tamaño de los racimos, permite a los productores monitorear efectivamente la evolución de sus viñedos en diversas etapas de crecimiento y predecir su rendimiento. Sin embargo, los métodos para determinar el tamaño de bayas y racimos son, generalmente, manuales; y por lo tanto altamente demandantes de tiempo. Esto incide directamente en el bajo número de muestras y alto costo en recursos humano que es factible de obtener, lo que conduce a resultados imprecisos. Por este motivo, automatizar este proceso supone estrechar una brecha que actualmente impacta en la certeza y robustez de los modelos de estimación.

En esta tesis se presenta un método automático de caracterización de racimos, basado en el procesamiento de imágenes digitales adquiridas en un ambiente controlado. El método requiere capturar 12 imágenes, alrededor del racimo, e identificar y caracterizar el contorno de bayas y racimo de manera

automática. El algoritmo, detecta las bayas empleando técnicas de detección de círculos, aplicadas sobre imágenes previamente segmentadas con K-means. Este algoritmo de detección tiene un R^2 de 0,67 para datos de entrenamiento y prueba lo que lo hace adecuado como predictor de número de bayas en racimos de uva.

**DEVELOPMENT OF A DIGITAL IMAGES ACQUISITION SYSTEM
ORIENTED TO THE PROCESSING AND EVALUATION OF TABLE GRAPE
CLUSTERS.**

Keywords: Clustering algorithms, Image acquisition network, Table grape.

ABSTRACT

Continuous monitoring of vineyards, especially of quality-related attributes, is essential to ensure good production. In particular, determining bunch size allows growers to effectively monitor the evolution of their vineyards at several growing stages and predict yields. However, methods for determining berry and bunch size are generally manual and therefore, highly time-consuming, to such an extent that only a small number of samples can be obtained, leading to inaccurate results. For this reason, an automatic method of cluster characterization, based on the processing of digital images, acquired in a controlled environment, is presented. The method requires capturing 12 images around the bunch, identifying the outline of berries and bunch. The algorithm detects the berries using circle detection techniques, applied on images previously segmented with K-means. This detection algorithm has an R^2 of 0.67, which makes it suitable as a predictor of berry number in grape clusters.

1. INTRODUCCIÓN

La capacidad de cuantificar los rasgos de la vid puede proporcionar un conocimiento valioso para los productores; les permite llevar un mejor control de sus campos y satisfacer más eficazmente las demandas de la industria. Actualmente, la determinación de aspectos cualitativos y cuantitativos de racimos de uva, se lleva a cabo mediante métodos manuales y con un número reducido de muestras, debido a que es una labor con alta demanda de tiempo y capacidades humanas. Dicha labor se vuelve pesada y más aún en viñedos comerciales de gran extensión, ya que se requiere de la disponibilidad de personal capacitado para realizar mediciones y recorrer largas distancias para llegar a las zonas en estudio. Por este motivo, automatizar este proceso supone estrechar una brecha que actualmente impacta en la certeza y robustez de los modelos de estimación de producción y calidad en vides.

El rendimiento es uno de los rasgos más medidos y complejos en la vid (Fanizza et al, 2005) debido a la alta variación en los rendimientos estacionales. En efecto, pronosticar y el controlar el rendimiento son dos de las tareas principales en la viticultura. En particular, el rendimiento biológico real, descrito como peso por vid, se pronostica estadísticamente mediante el peso del racimo, número de racimos, número de bayas por racimo y peso de la baya. por consiguiente, aplicar técnicas no destructivas para obtener parámetros de rendimiento es de gran interés para este rubro.

En los últimos años, se han desarrollado varios enfoques basados en imágenes 2D orientados a detectar racimos de uva (Liu et al,2013), diámetro de bayas (Roscher et al,2014) o número de bayas (Nuske et al,2014).

Los investigadores han aplicado técnicas de visión por computadora para la caracterización de frutos y la estimación del rendimiento (Mochida et al., 2018). Esto, ya que la visión por computadora incorpora múltiples técnicas de procesamiento de imágenes para interpretar y extraer información precisa de conjuntos de datos digitales (González et al., 2009). En efecto, las técnicas de visión por computadora, incluida la segmentación, extracción de características y clasificación, son ideales para extraer información de conjuntos de datos sin procesar en agricultura (Mochida et al., 2018; Tian et al., 2020).

Dentro de estas técnicas, la segmentación correcta, de imágenes de viñedos, presenta uno de los mayores desafíos en el proceso de estimación del rendimiento (Millan et al., 2018). Los métodos de segmentación, generalmente, utilizan estrategias de umbralización de color para clasificar los valores de píxeles de acuerdo con las clases relevantes (es decir, objeto de interés y fondo) (Reis et al., 2012). Luego, en la etapa siguiente, post-segmentación, normalmente se efectúan operaciones morfológicas, sobre los píxeles, aplicadas comúnmente para 'filtrar' y 'limpiar' la imagen segmentada de píxeles que no pertenecen al objeto de interés (Millan et al., 2018).

Por otra parte, el proceso de segmentación se ve fuertemente afectado por las condiciones de iluminación. En efecto, cuando se implementa la captura de imágenes con iluminación natural, esta tiende a generar inconsistencias en los análisis de imágenes (Font et al., 2015), principalmente debido a la generación de claroscuros que alteran en apariencia los colores de la imagen.

Como una forma de resolver este problema, algunos autores sugieren el uso de imágenes adquiridas de noche con fuentes de luz externas (Nuske et al., 2014; Reis et al., 2012) o el control de la iluminación natural utilizando una metodología estándar para la adquisición de imágenes, es decir, estandarizar la hora de captura, ángulo solar, distancia y condiciones climáticas (Hacking et al., 2019).

De este modo, considerando la necesidad de contar con sistemas automáticos y no invasivos que permitan caracterizar racimos de uva de mesa en terreno y considerando los efectos de la iluminación irregular sobre este proceso, en esta tesis se propone implementar un sistema de captura de imágenes digitales, en un ambiente controlado y desarrollar un software de procesamiento y extracción de características relevantes de racimos de uva de mesa. Además, se propone crear una base de datos con características morfológicas de los racimos, obtenida manualmente, de modo que permita validar los resultados de los algoritmos de caracterización desarrollados.

2.HIPÓTESIS

A partir de estrategias de procesado digital de imágenes, obtenidas en condiciones controladas, es posible una metodología que permita caracterizar morfológicamente racimos de uva de mesa.

3. OBJETIVOS

3.1.Objetivo general

Desarrollar un sistema de adquisición y procesado de imágenes digitales para la extracción de características morfológicas de racimos de uva de mesa en condiciones ambientales controladas.

3.2.Objetivos específicos

Diseñar e implementar un sistema de adquisición de imágenes digitales de racimos de uva de mesa, en condiciones controladas.

Desarrollar e implementar un algoritmo que permita procesar las imágenes y obtener características morfológicas de los racimos de uva de mesa.

Generar un conjunto de datos que incluya, características morfológicas, peso, calibre y número de bayas de cada racimo empleado en este estudio.

4. ANTECEDENTES GENERALES

4.1. Visión por computadora

La inspección automática de calidad externa de frutas y verduras sigue siendo un arduo trabajo, pues actualmente la mayor parte de los atributos de calidad externos se inspeccionan de manera visual; la visión por computadora proporciona un medio para realizar esta tarea automáticamente (Aleixosa et al, 2002). La visión por computadora es una tecnología de ingeniería que combina mecánica, instrumentación óptica, detección electromagnética, video digital y tecnología de procesamiento de imágenes (Patel et al, 2012). Es la ciencia responsable del estudio y la aplicación de los métodos que permiten que una computadora entienda el contenido de una imagen, y esta interpretación implica la extracción de ciertas características que son importantes para un objetivo determinado (Gomes y Leta, 2012). En los últimos años, con el rápido desarrollo de la ciencia, el procesamiento de imágenes y la tecnología de reconocimiento de patrones, así como el hardware y software, la visión por computador se ha consolidado como una herramienta científica para inspección de la calidad y seguridad de una variedad de productos alimentarios y agrícolas. La inspección de calidad automática no invasiva, tiene como objetivo duplicar el efecto de la visión humana al percibir y comprender electrónicamente una imagen (Brosnan y Sun, 2002), reconocer e interpretar los caracteres externos de frutas y verduras.

4.2. Algoritmos de Agrupamiento

En el ámbito de identificación de objetos, uno de los enfoques más empleados para identificar objetos, presentes en una imagen, es su forma. Por ejemplo, muchos frutos tienen formas circulares o elípticas, susceptibles de ser identificadas mediante técnicas tales como la transformada circular de Hough (Roscher et al., 2014). Sin embargo, estas técnicas requieren de imágenes con la menor cantidad de perturbaciones posible, entendiendo como perturbaciones todo aquello que no sea el objeto de interés. En este sentido, algoritmos de segmentación que permitan aislar los objetos de interés, del resto de la escena, son esenciales para el buen desempeño de los algoritmos de identificación de círculos.

Una de las técnicas de segmentación que mejores resultados entrega, son aquellas basadas en agrupamiento de píxeles de similares características, ya que utiliza múltiples umbrales para la separación por grupos de colores.

En términos generales, el análisis de agrupamiento o de clústeres, se define como un conjunto de técnicas, de agrupación de datos, que se utilizan para agrupar objetos de similares características o segmentar conjuntos de datos en subconjuntos denominados grupos.

Uno de los algoritmos de agrupamiento más utilizados, es el denominado K-Means. Este algoritmo de partición rígida, asigna cada objeto (dato) a un único grupo; mientras que los algoritmos de partición suave o agrupación difusa como Fuzzy C-means (FCM) asignan cada objeto a diferentes grupos con

diversos grados de pertenencia. En otras palabras, mientras que la pertenencia a un clúster o grupo, es exactamente 0 o 1, en K-Means, en FCM toma valores entre 0 y 1.

De este modo, en los casos en que no sea posible decidir fácilmente si los objetos pertenecen a un solo clúster, especialmente con los conjuntos de datos que tienen ruidos o valores atípicos, FCM tiene un mejor desempeño que K-Means (Cebeci y Yaldiz, 2015).

Así, con el propósito de detectar bayas en racimos de uva, cuyas formas son generalmente circular, se propone emplear una metodología basada en segmentación vía FCM y K-Means e identificar círculos (bayas) mediante la transformada circular de Hough.

5. METODOLOGÍA

5.1. Adquisición de imágenes

Las imágenes fueron adquiridas en Agrícola C.V. (Pimpihue), campo Walpon, ubicado en callejón los perros, comuna de Rengo, Sexta región. La variedad elegida fue Crimson Seedless.

Para la captura de imágenes, se introdujo el racimo en forma vertical al interior de una caja de madera, de 60 cm de ancho 60 cm de largo y 40 cm de alto, cerrada y forrada en el interior con papel blanco opaco, formato A4. El papel cumple la función de homogenizar el fondo y de reflejar la luz de modo difuso, evitando reflejos brillantes al interior.

La caja dispone de dos aperturas, una para el lente de la cámara (Nikon semi profesional COOLPIX L810), ubicada en un costado de la caja y otra abertura en la parte superior de la caja para el raquis del racimo. El racimo queda ubicado a 30 cm del lente con la finalidad de que el racimo quede por completo dentro del campo visual de la cámara, independiente del tamaño.

Para iluminar el espacio al interior de la caja, se utilizó un panel led cuadrado de las mismas dimensiones que la caja (60 cm x 60 cm), de luz cálida de 45 W, 3500 lm; de esta forma no se generan sombras.

Se tomó doce imágenes RGB de cada racimo (40 racimos en total); cada 30° se capturaba una imagen, es decir, 30, 60, 90, 120, 150, 180, 210, 240, 270, 300, 330 y 360°, respectivamente. Para asegurar este proceso, se tomó un transportador de 360° y se sujetó al raquis del racimo por el medio de éste.

Con una referencia inicial sobre la caja se realizó el procedimiento girando el racimo.




Figura 1. Caja de madera con un soporte para el racimo e iluminación con panel led, luz cálida. (Elaboración propia).

5.2. Selección de canales y Espacio de color

Previo al procesamiento de las imágenes RGB, estas fueron transformadas a los espacios de color, HSV, L^*a^*b e Ycbcr, para determinar cuál de ellos permite una mejor segmentación.

5.3.Extracción de característica con software

El procesamiento y extracción de características de las imágenes se realizó mediante el software Matlab 2018®. En particular, se utilizó el set de herramientas de procesamiento de imágenes denominado “Image Processing Toolbox ®”

5.3.1.Ajuste de contraste

Con el propósito de realzar el contraste entre racimo y fondo, se utilizó la función “imadjust” de Matlab. Este proceso, que consiste en aumentar las variaciones de intensidad, ajustando la imagen RGB en cada canal. La función “imadjust” ajusta el contraste de la imagen para que el 1% de los datos se sature a intensidades bajas y altas.

5.3.2.Segmentar

En este trabajo se utilizó dos algoritmos segmentación por agrupación: K-Means y Fuzzy C-Means (FCM). K-means es un algoritmo no supervisado que se utiliza para segmentar el área de interés del fondo. Agrupa o divide los datos entregados en K-grupos o K-clusters, agrupados entorno los K-centroides o prototipos de cada grupo; en este caso, dos grupos racimo y fondo.

Por su parte, Fuzzy C-Means es un algoritmo de agrupamiento difuso, que asigna un valor de membresía a cada pixel, valor que es inversamente proporcional a la distancia relativa desde el punto al prototipo del grupo. Una vez realizado el agrupamiento, se identifican los grupos creados, asignando manualmente una etiqueta, según la clase a la que corresponda, en este caso,

Fondo, Raquis o Baya. Luego el procesamiento continúa utilizando solo el o los clústeres que contengan pixeles del objeto de interés, en este caso pixeles de uva, es decir, raquis o baya.

Después de identificado el clúster que contiene el racimo y con el fin de identificar de manera óptima los elementos de interés presentes en éste (bayas del racimo), se elimina el raquis y sombras que pudieron quedar del proceso de segmentaciones con K-Means y Fuzzy C-Means. Esta eliminación del raquis se efectúa mediante una estrategia de segmentación por umbralización de histograma (Color Thresholder)

5.3.3. Relleno imagen resultante

Para identificar mejor los elementos de interés (bayas) presentes en la imagen e identificar de buena manera las formas subyacentes, se aplicó técnicas de relleno de datos, provistas por Matlab (imfill, imclose, entre otras).

5.3.4. Extracción de características

Las características relevantes que se busca identificar y cuantificar guardan relación con el número de bayas, su tamaño y con las características morfológicas del racimo. Debido a que las bayas tienen una forma circular, se implementó un algoritmo que busca identificar y cuantificar los círculos presentes en la imagen. La identificación de círculos se implementó mediante el uso de la transformada circular de Hough, en imágenes 2D, implementada como "imfindcircles" de Matlab.

La búsqueda, solo se realiza para círculos que se encuentren en un rango predefinido de radios (vector de dos elementos [r min, r max]). La función, retorna las coordenadas del centro geométrico, en una matriz de dos columnas. El número de círculos detectados corresponde al número de filas de la matriz.

Además, se extrajo el área del racimo mediante la función “bwarea” esta estima el área de los objetos en imagen binaria. Es un escalar cuyo valor corresponde aproximadamente al número total de píxeles de la imagen, pero puede que no sea exactamente el mismo porque los diferentes patrones de píxeles se ponderan de forma diferente.

5.4. Generación conjunto de datos

Con el fin de generar información para futuras investigaciones y desarrollar algoritmos de caracterización de uva de mesa, se midió diversos parámetros, de los racimos en estudio, de forma manual. En particular, se midió el peso, largo del racimo, número de bayas del racimo y calibre del racimo, correspondiendo calibre 900 a bayas sobre los 19 mm y calibre 700, a bayas desde los 17,5 mm a los 18,9 mm. Se separaron 30 racimos para dejarlos como datos de entrenamiento y 10 para dejarlos como prueba. Finalmente, se estableció la correlación entre el número de bayas detectadas mediante los dos algoritmos de agrupación, K-means y Fuzzy C-means en conjunto con detección de círculos. Adicionalmente se calculó el área promedio de los racimos, en las 12 imágenes y se estableció el grado de correlación entre el

número de bayas detectadas y el real, además de establecer el grado de correlación entre el peso medido y el área detectada por los algoritmos implementados. Finalmente, se determinó el porcentaje de error para ambos casos.

6. RESULTADOS

6.1. Adquisición de imágenes

Se obtuvo un total de 480 imágenes de racimos de la variedad Crimson Seedless (40 racimos, 12 imágenes por racimo). En las imágenes se observan problemas de homogeneidad del fondo. Aparecen líneas en las esquinas debido a que el papel no fue instalado correctamente. Al procesar las imágenes, algunas evidenciaron el trazo oscuro proveniente de esos malos empalmes. El hecho de iluminar la caja solo en la parte inferior ocasionó sombras alrededor del raquis, proyectadas por el racimo. Para solucionarlo, el algoritmo incorporó una etapa de eliminación de este efecto.

Estos problemas pudieron ser evitados forrando la caja adecuadamente e iluminando el racimo también desde el frente de la caja. Lo anterior se corrigió, pero no a tiempo para seguir con las pruebas debido a la disponibilidad de fruta, se tomó la decisión de continuar.



Figura 2. Imagen con problemas en las paredes interiores y sombra generada por el racimo, obtenida desde la adquisición de imágenes. (Elaboración propia).

6.2. Selección de canales y Espacio de color

Los resultados de convertir las imágenes a diferentes espacios de color se ejemplifican en las Figuras 3,4,5.





Figura 3. Imagen de un racimo de uva de mesa en el espacio de color RGB y sus canales. (Elaboración propia).

Canal L



Canal a



Canal b



Espacio de color Lab




Figura 4. Imagen de un racimo de uva de mesa en el espacio de color $L^* a^* b^*$ y sus canales. (Elaboración propia).

Canal H



Canal S



Canal V



Espacio de color HSV




Figura 5. Imagen de un racimo de uva de mesa en el espacio de color HSV y sus canales. (Elaboración propia).




Figura 6. Imagen de un racimo de uva de mesa en el espacio de color Ycbr y sus canales. (Elaboración propia).

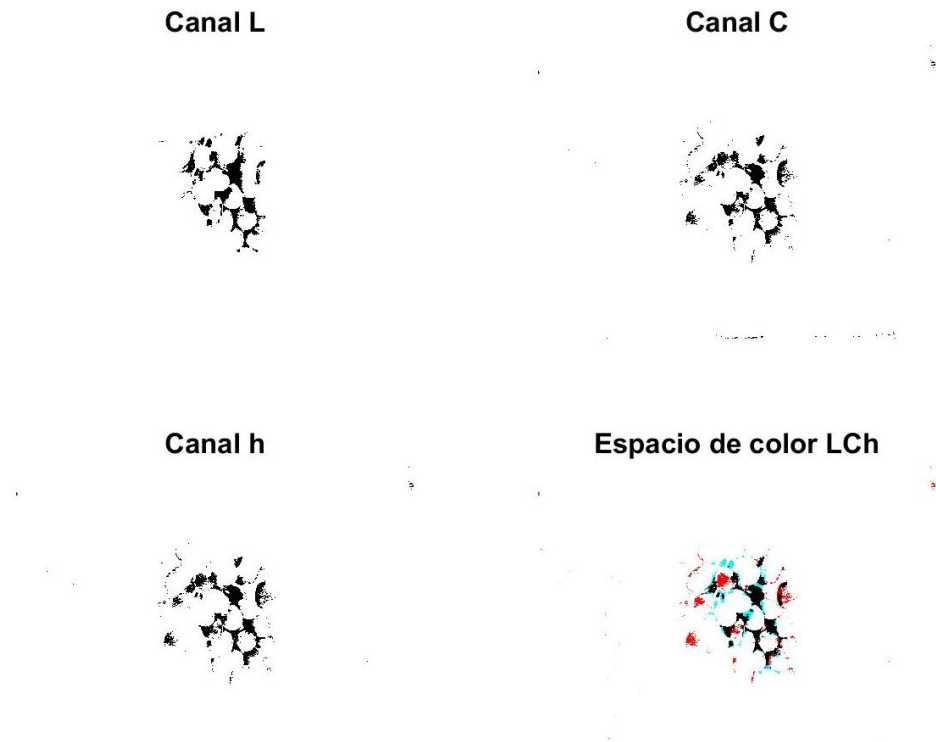


Figura 7. Imagen de un racimo de uva de mesa en el espacio de color $L^*C^*h^*$ y sus canales. (Elaboración propia).

Dado que la correlación entre los canales R, G y B es alta y la medición de la distancia no puede resolver la diferencia de color en el espacio RGB, este espacio de color no es una opción ideal para la segmentación de color.

A diferencia del espacio RGB, el espacio de color $L^*a^*b^*$ puede proporcionar información de intensidad y color de forma independiente. Además, expresa la diferencia de color percibida por los humanos a través de la distancia euclidiana; así también el espacio de color L^*C^*h , pero este con coordenadas polares.

6.3.Filtrar

El resultado de realzar la imagen es tener una imagen más clara que la imagen original, permitiendo un mejor desarrollo del programa.




Figura 8. Efecto de realzar una imagen. Se puede notar que la imagen de la derecha está más clara que la de la izquierda, por lo que los bordes de los objetos contenidos pueden ser identificados de mejor modo. (Elaboración propia).

6.4. Métodos de agrupamiento por color

6.4.1. K-Means

En cuanto al algoritmo de clasificación aplicado a las imágenes, K-Means, usando dos clases y aplicado sobre el espacio L^*C^*h , es capaz de separar apropiadamente el racimo del fondo alcanzando niveles de acierto del 100%, es decir el 100% de los pixeles reportados como fondo son fondo, mientras que un 98% de los pixeles identificados como racimo, pertenecen a la clase racimo (véase Figura9 derecha).

En las pruebas se evaluó el algoritmo con 2 a 6 grupos. El aumento del número de clases, no mostró una mejoría, ya que persistió el agrupamiento de pixeles de parte del fondo con pixeles de racimos. Por esto, se empleó solo 2 grupos. Respecto al tiempo de proceso, 480 fotos tardaron 581.08 segundos. en un notebook Asus modelo N552V de 2.6 GHz. (1,21 segundos/imagen)



Figura 9. Resultado de la clasificación usando K-Means, en Matlab, con dos grupos sobre el espacio de color $L^*c^*h^*$. A la derecha el clúster que contiene el racimo o la información de interés y a la izquierda clúster 1 enmascarado con la imagen original. (Elaboración propia).

Con el propósito de separar píxeles de fondo en el Cluster 1, se aplicó nuevamente el algoritmo de agrupamiento K-Means, sobre el clúster de interés (en este caso Cluster 2). Esto no genera buenos resultados ya que no se consigue separar todos los píxeles del fondo del racimo. Por lo tanto, se requiere una separación por color para lograr separar los píxeles de fondo remanentes.

6.4.2.Fuzzy C-Means

La clasificación con Fuzzy C-Means separa correctamente el fondo del racimo; en términos generales, separa de mejor manera el racimo del fondo, como se observa en la Figura 10, comparado con los resultados de k-means en la Figura 9. Para esta clasificación se utilizó dos clases y el espacio de trabajo L^*a*b . Por otra parte, el tiempo de procesamiento de este algoritmo es de 4,75 segundos por imagen en un Notebook Asus modelo N552V de 2.6 GHz.




Figura 10. Resultado de la clasificación aplicando Fuzzy C-Means, sobre el cluster 1 para separar fondo de racimo. A la izquierda, el clúster que contiene el racimo o información de interés enmascarada a partir de la imagen original y a la derecha el clúster resultante de la clasificación. (Elaboración propia).

6.5.Segmentación de color

Con el propósito de eliminar los pixeles de fondo y el raquis en las imágenes de racimos se implementó una separación por color. En efecto, esta técnica eliminó el raquis y la sombra en gran parte de las imágenes evaluadas, además, se observan elementos de interés “limpios” (bayas), esto se logró utilizando la herramienta Color Thresholder de Matlab, con los umbrales mínimos y máximos para los canales R [0;90], G [-5;100] y B [-20;100] y rellenando los huecos producidos en la umbralización. Como se puede apreciar en la imagen de la Figura 11.

Sin embargo, un pequeño grupo de estas imágenes queda con sombras en la parte superior. Como se muestra en la imagen de la Figura 12, producto de la escasa separación entre la parte superior de la caja y el racimo.



Figura 11. Clúster con elementos de interés limpios (bayas), raquis y sombra eliminadas. (Elaboración propia).



Figura 12. Clúster con sombra en la base del raquis, producto de problemas no resueltos por la segmentación. Aparece en tonos gris claro. (Elaboración propia).

Los resultados de la segmentación presentados, proporcionan información sobre el desempeño de las dos técnicas evaluadas en este estudio, es decir: K-means y Fussy C-means. Como se aprecia en las imágenes (Figura 9 y Figura 10), ambas técnicas generaron un clúster en el que estaba presente únicamente el racimo de uva de mesa.

En general, la clasificación sin supervisión tiende a mostrar problemas en imágenes con muchas características, como un viñedo con propiedades estructuralmente variables (Diago et al., 2012), sin embargo, al incluir un fondo blanco permitió superar esta limitante. Por otra parte, la combinación de la técnica adquisición, más la segmentación mediante K.means o Fuzzy C means resulta simple y práctica para la adquisición de datos a nivel de un grupo grande de muestras tomadas en terreno, con un rendimiento adecuado, para la segmentación, en ambos casos, como lo demuestran los resultados. Sin









embargo, el tiempo de procesamiento es significativamente diferente, siendo cuatro veces superior el de Fuzzy C-means comparado con K-means.

6.6.Extracción de características

Se extrajeron características de cada racimo tales como área, perímetro y número de bayas a partir de funciones de Matlab tales como `bwarea`, `Regionprops`, `FindCircles`

Como se puede apreciar en la secuencia de imágenes de la Figura 13, al aplicar la Transformada circular de Hough, implementada en la función `Findcircles`, sobre las imágenes de clúster racimo, se genera un número significativo de detecciones de círculos (213 círculos en promedio por racimo). Esto, tanto para las imágenes generadas a partir de K-means como de Fuzzy C-Means, en ambos casos mejoradas con la segmentación de color. De este modo, pueden ser empleados para la identificación de bayas, como se aprecia en la Tabla 2 y Tabla 3. La aplicación de la detección de círculos no entrega falsas detecciones, cuando se realizan búsquedas de círculos con un radio entre 70 y 140 píxeles, sin tolerancia para incluir círculos concéntricos.

Además, al aplicar la función `"bwarea"` sobre la imagen segmentada (imagen binaria), permite determinar el número de píxeles del objeto segmentado. Al correlacionar el número de píxeles de cada racimo con el peso de los racimos la correlación muestra un R^2 de un 98% en la predicción peso promedio de racimos, como se puede apreciar en la Tabla 2 y Tabla 3.






Figura 13. Resultado de la detección de círculos en las doce imágenes de un racimo. Búsquedas de círculos con un radio entre 70 y 140 píxeles, sin tolerancia para incluir círculos concéntricos. (Elaboración propia).

Luego, se obtuvo de cada imagen, el número de círculos detectados por racimo y se buscó la relación de estos con el número de bayas real, cuestión que se puede apreciar en las tablas y gráficos siguientes (Figura 14, Figura 15, Tabla 1 Tabla 2 y Tabla 3).

6.7. Conjunto de datos

Tabla 1.-Variables medidas a los racimos de estudio de manera manual como el peso, largo del racimo, número de bayas del racimo, y calibre del racimo correspondiendo 900 a bayas sobre los 19 mm y 700 bayas desde los 17,5 mm a los 18,9 mm.

N° Racimo	Peso (g)	Largo (cm)	N°de bayas	Peso promedio de bayas	Calibre
1	517	16.0	70	7.4	900
2	592	17.7	106	5.6	900
3	537	17.9	111	4.8	700
4	516	14.7	98	5.3	900
5	615	15.8	92	6.7	700
6	607	16.5	93	6.5	900
7	482	14.6	65	7.4	700
8	461	15.2	70	6.6	900
9	465	15.4	86	5.4	900
10	609	18.9	76	8.0	900
11	360	13.1	81	4.4	700
12	767	14.8	95	8.1	900
13	483	16.3	58	8.3	900
14	389	13.6	60	6.5	900
15	412	11.9	78	5.3	700
16	832	18.7	146	5.7	700
17	488	13.2	84	5.8	700
18	584	21.0	80	7.3	900
19	693	16.5	132	5.3	700
20	434	15.0	54	8.0	900
21	439	14.8	59	7.4	900
22	506	14.4	78	6.5	900
23	453	16.6	84	5.4	700
24	599	17.2	75	8.0	700
25	575	17.5	96	6.0	700
26	557	13.4	81	6.9	900
27	521	12.8	68	7.7	900
28	525	13.0	105	5.0	700
29	687	14.1	102	6.7	700
30	497	15.0	89	5.6	700
Promedio	540.07	15.52	85.73	6.54	

Nota: Elaboración propia.

Tabla 2.-Variables medidas a los racimos de prueba de manera manual como el peso, largo del racimo, número de bayas del racimo, y calibre del racimo correspondiendo 900 a bayas sobre los 19 mm y 700 bayas desde los 17,5 mm a los 18,9 mm.

N° Racimo	Peso (g)	Largo (cm)	N°de bayas	Peso promedio de bayas	Calibre
31	838	20.1	128	6.5	900
32	547	15.3	109	5.0	700
33	542	13.0	87	6.2	700
34	487	11.8	53	9.2	700
35	415	12.5	64	6.5	700
36	349	15.7	61	5.7	700
37	601	14.4	97	6.2	900
38	455	14.7	75	6.1	700
39	577	15.4	79	7.3	900
40	387	19.4	67	5.8	700
Promedio	519.80	15.23	82,00	6.45	

Nota: Elaboración propia.

Tabla 3.-Variables obtenidas con datos de entrenamiento, con programa utilizando el algoritmo de agrupación K-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real.

Nº Racimo	Círculos detectados	Bayas según formula	Error (%)	Área (pixeles)	Peso según Formula	Error (%)
1	176	67,3	3,8	128593,4	515,7	0,2
2	240	97,9	7,6	157489,4	648,6	9,6
3	244	99,8	10,1	150162,8	614,9	14,5
4	198	77,8	20,6	125995,7	503,8	2,4
5	254	104,6	13,7	153773,8	631,5	2,7
6	240	97,9	5,3	143295,8	583,3	3,9
7	187	72,6	11,7	128806,4	516,7	7,2
8	168	63,5	9,3	126100,3	504,2	9,4
9	211	84,1	2,3	115300,7	454,6	2,2
10	235	95,5	25,7	156623,6	644,6	5,9
11	188	73,1	9,8	94971,2	361,0	0,3
12	217	86,9	8,5	171205,0	711,7	7,2
13	173	65,9	13,6	120637,8	479,1	0,8
14	193	75,5	25,8	110934,2	434,5	11,7
15	192	75,0	3,9	112058,9	439,7	6,7
16	324	138,0	5,5	191014,6	802,8	3,5
17	190	74,0	11,9	119810,9	475,3	2,6
18	238	96,9	21,2	159266,9	656,8	12,5
19	261	107,9	18,2	163448,2	676,0	2,4
20	174	66,4	22,9	107056,4	416,6	4,0
21	171	65,0	10,1	108290,6	422,3	3,8
22	204	80,7	3,5	125751,9	502,6	0,7
23	203	80,2	4,5	111318,0	436,2	3,7
24	247	101,2	35,0	139014,8	563,6	5,9
25	255	105,1	9,4	148971,5	609,4	6,0
26	212	84,5	4,4	129147,0	518,3	7,0
27	165	62,1	8,7	125303,4	500,6	3,9
28	212	84,5	19,5	130282,1	523,5	0,3
29	243	99,3	2,6	153082,9	628,4	8,5
30	220	88,4	0,7	137949,7	558,7	12,4
Promedio	214,50	85,73	11,65	134855,26	544,51	5,40

Nota: Elaboración propia.

Tabla 4.-Variables obtenidas con datos de entrenamiento, con programa utilizando el algoritmo de agrupación Fuzzy C-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de acierto según el real.

Nº Racimo	Círculos detectados	Bayas según formula	Error (%)	Área	Peso según Formula	Error (%)
1	173	69,4	0,9	129330,5	515,2	0,3
2	235	97,1	9,1	157180,5	643,3	8,7
3	244	102,0	8,8	150219,0	611,3	13,8
4	199	79,8	22,8	125426,7	497,2	3,6
5	252	106,5	13,6	153232,6	625,2	1,7
6	245	102,5	9,3	143296,9	579,4	4,5
7	189	75,6	14,0	128752,1	512,5	6,3
8	161	65,1	7,5	127114,2	505,0	9,5
9	203	81,5	5,5	115428,7	451,3	3,0
10	230	94,5	19,6	157557,2	645,0	5,9
11	192	76,8	5,5	95227,8	358,3	0,5
12	207	83,3	14,0	170587,4	705,0	8,1
13	174	69,7	16,8	120630,4	475,2	1,6
14	184	73,6	18,4	111898,0	435,0	11,8
15	193	77,2	1,0	112594,6	438,2	6,4
16	311	144,8	0,8	190556,4	796,8	4,2
17	192	76,8	9,4	119671,6	470,8	3,5
18	236	97,7	18,1	158963,8	651,5	11,6
19	256	108,8	21,3	163255,1	671,3	3,1
20	175	70,1	23,0	107129,4	413,1	4,8
21	170	68,3	13,6	108234,7	418,2	4,7
22	204	82,0	4,9	125826,1	499,1	1,4
23	202	81,1	3,6	111389,2	432,7	4,5
24	239	99,3	24,4	138086,7	555,5	7,3
25	261	111,8	14,1	149308,0	607,1	5,6
26	214	86,6	6,5	129271,7	514,9	7,6
27	160	64,8	4,9	125769,4	498,8	4,3
28	205	82,4	27,4	131973,8	527,4	0,4
29	243	101,4	0,5	153289,1	625,4	9,0
30	223	91,0	2,2	138363,3	556,8	12,0
Promedio	212,40	87,38	11,38	134985,50	541,22	5,66

Nota: Elaboración propia




Figura 14. Relación del número de bayas real con el número de círculos detectados utilizando findcircles sobre las imágenes generadas mediante agrupación por K-means. (Elaboración propia).




Figura 15. Relación del número de bayas real con el número de círculos detectados utilizando findcircles sobre las imágenes generadas mediante agrupación por Fuzzy C-means. (Elaboración propia).




Figura 16. Relación del peso del racimo con el número de bayas obtenidas de la ecuación de regresión lineal de la Figura 14. (Elaboración propia).

Aquí se puede observar que el número de bayas detectadas se correlaciona de forma muy cercana con el peso, siendo levemente inferior que el predictor que emplea el número de bayas reales (R^2 0,66 vs R^2 0,61)

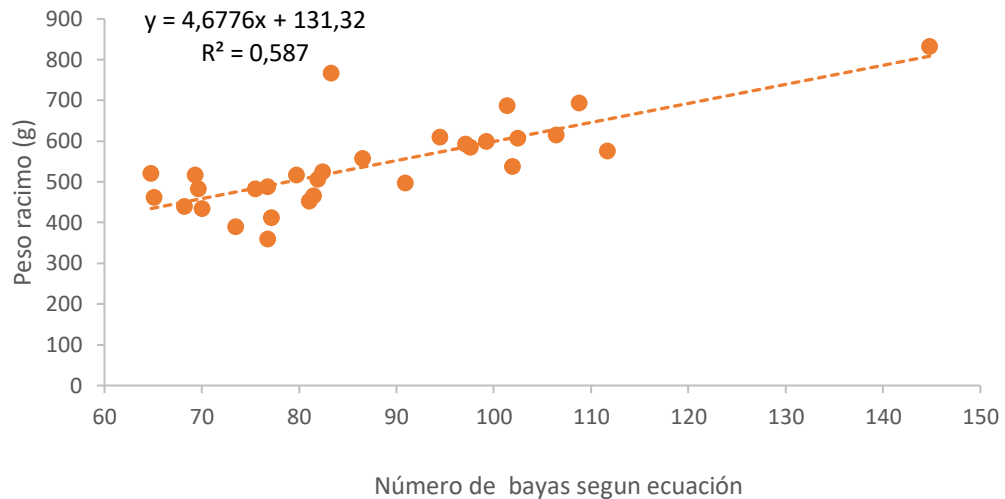


Figura 17. Relación del peso del racimo con el número de bayas obtenidas de la ecuación de regresión lineal de la Figura 15. (Elaboración propia).

Se puede observar que el número de bayas detectadas se correlaciona de forma muy cercana con el peso, siendo levemente inferior que el predictor que emplea el número de bayas reales (R^2 0,64 vs R^2 0,58)

Examinando los gráficos es posible afirmar que existe correlación entre el número de bayas detectadas y el número real medido, ya que el valor de R^2 es superior 0.6; en concreto, más de un 64% de la variabilidad de la variable Y (Número real de bayas) respecto a su promedio, es explicado por el modelo de regresión ajustado. Adicionalmente a partir de esta información es posible afirmar que entre K-means y Fuzzy C-means no hay diferencias significativas. Por otra parte, al realizar ajustes, separando los racimos según los calibres de los racimos, es decir, 700 y 900, el R^2 no mejora (baja alrededor de un 2 % en el mejor de los casos), por lo que hacer esta separación no sería conveniente.

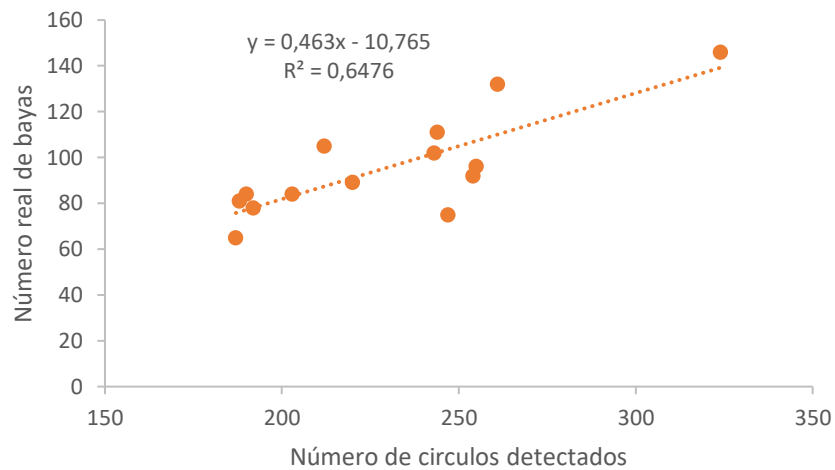


Figura 18. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación K-means, solo con racimos de calibre 700. (Elaboración propia).




Figura 19. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación K-means, solo con racimos de calibre 900. (Elaboración propia).




Figura 20. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación Fuzzy C-means, solo con racimos de calibre 700. (Elaboración propia).




Figura 21. Relación del número de bayas real con el número de círculos detectados utilizando el algoritmo de agrupación Fuzzy C-means, solo con racimos de calibre 900. (Elaboración propia).




Figura 22. Relación del peso del racimo con el área en píxeles utilizando el algoritmo de agrupación K-means. (Elaboración propia).

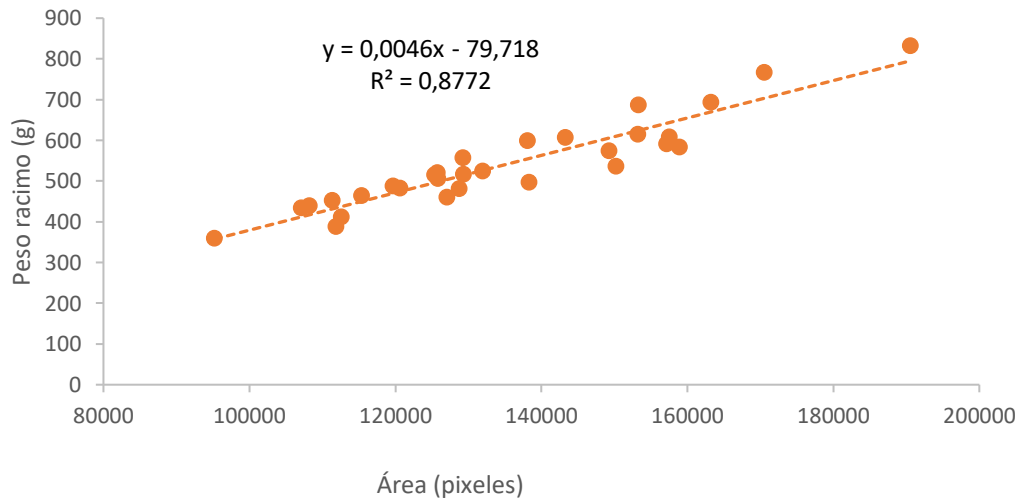


Figura 23. Relación del peso del racimo con el área en píxeles utilizando el algoritmo de agrupación Fuzzy C-means. (Elaboración propia).

Tabla 5.- Variables obtenidas con datos de prueba, con programa utilizando el algoritmo de agrupación K-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real.

N° Racimo	Círculos detectados	Bayas según formula	Error (%)	Área	Peso según Formula	Error (%)
31	326	139,0	8,6	191245,4	803,9	4,1
32	242	98,9	9,3	135756,1	548,7	0,3
33	195	76,4	12,2	127460,2	510,5	5,8
34	184	71,2	34,3	116422,2	459,7	5,6
35	175	66,9	4,5	112473,3	441,6	6,4
36	191	74,5	22,1	98433,2	377,0	8,0
37	205	81,2	16,3	144574,2	589,2	2,0
38	185	71,6	4,5	114389,4	450,4	1,0
39	192	75,0	5,1	133904,7	540,1	6,4
40	225	90,7	35,4	116537,8	460,3	18,9
Promedio	212,00	84,53	15,22	129119,64	518,13	5,85

Nota: (Elaboración propia).

Tabla 6.- Variables obtenidas con datos de prueba, con programa utilizando el algoritmo de agrupación Fuzzy C-means. Círculos detectados y área en pixeles en las 12 imágenes, bayas y peso según la formula lineal, el porcentaje de error según el real.

N° Racimo	Círculos detectados	Bayas según formula	Error (%)	Área	Peso según Formula	Error (%)
31	311	144,8	11,6	190656,7	797,3	4,9
32	247	103,7	5,2	135113,9	541,8	0,9
33	195	78,1	11,4	127091,0	504,9	6,8
34	186	74,4	28,7	115839,8	453,1	7,0
35	178	71,2	10,1	112498,8	437,8	5,5
36	192	76,8	20,6	97668,2	369,6	5,9
37	200	80,2	20,9	144522,9	585,1	2,6
38	182	72,8	3,1	115033,4	449,4	1,2
39	193	77,2	2,3	134032,4	536,8	7,0
40	231	95,0	29,5	116790,8	457,5	18,2
Promedio	211,50	87,42	14,34	128924,78	513,34	6,00

Nota: (Elaboración propia).

En este estudio se estimó el número de bayas a nivel de racimo mediante una metodología 2-D, resultante de imágenes capturadas rotando el racimo, por lo que incluyen la tercera dimensión del racimo. La estimación arrojó que más de un 64% de la variabilidad del número real de bayas, respecto a su promedio, es explicado por el modelo de regresión ajustado.

Diago et al. (2015) llevó a cabo un estudio a nivel de racimo en condiciones de laboratorio de postcosecha. El estudio utilizó el número de bayas como métrica de rendimiento para estimar el rendimiento a cosecha, el estudio se realizó en un parrón variedad Tempranillo uva de bayas esféricas, de color negro púrpura. Los autores lograron un R global de 0,840, ($R^2= 0,7$) levemente superior a la R^2 (0,640) obtenida en este estudio. Del mismo modo, Liu et al. (2013) estimaron rendimiento, a nivel de racimo, en condiciones de laboratorio para variedad Syrah, variedad que se caracteriza por tener bayas esféricas y negro-azuladas.; los autores evaluaron varias métricas a nivel de píxel para la estimación del rendimiento, logrando una R^2 de 0,770, utilizando una métrica de recuento de píxeles; métrica no empleada en este estudio, ya que no ofrece la misma información que el número y tamaño de bayas. Sin embargo, en este estudio se obtuvo un área en píxeles que al relacionarla con el peso del racimo se obtiene un $R^2 =0,88$ como se puede ver en la Figura 24 y Figura 25, lo que mejora el resultado de Liu et al. (2013).

Por otra parte, se debe notar que, para comparar los resultados, es importante tener en cuenta que éste estudio se realizó empleando técnicas no

supervisadas para la segmentación de imágenes, enfoque que automatiza completamente el proceso, ya que no requiere intervención humana. Técnicas, que según Diago et al. (2012), pueden ser intrínsecamente poco fiables, cuando se le asigna la tarea de clasificar un entorno con componentes estructuralmente variables, como es el caso de los viñedos. Además, debe notarse que, las formas de las bayas de los estudios citados son esféricas, en lugar de elipsoides como los utilizados en este trabajo, por lo que es esperable un porcentaje de detección menor. Cuestiones que podrían explicar el ajuste obtenido.

Además, cabe destacar que en este trabajo el porcentaje de acierto para cada uno de los racimos puede llegar a variar en un 19% respecto a su peso según el área en píxeles, sin embargo, para el total de la muestra, en ambos casos de segmentación, el porcentaje de acierto puede llegar a un 99%.

7. CONCLUSIÓN

- El sistema para registrar las imágenes digitales es un sistema de fácil implementación y uso, provee resultados con errores de solo un 6% promedio por racimos en cuanto a su peso, si se controla el entorno de captura de la imagen, i.e. utilizando iluminación controlada y un fondo blanco, características que ayudan a mejorar el desempeño de los algoritmos de procesamiento. Sin embargo, se debe poner atención en aspectos constructivos, como esquinas mal selladas, que producen sombras que afectan la correcta segmentación.
- Sobre la implementación del algoritmo de procesamiento de imágenes y obtención de características de los racimos de uva, es posible señalar que ambas técnicas de segmentación empleadas generaron un clúster en el que solo estaba presente el racimo, por lo que se cumplió con el objetivo planteado de separar el racimo del resto de la escena.
- Los algoritmos de detección de círculos implementados permitieron contar de modo automático el número de bayas en cada una de las 12 imágenes de cada racimo, información que fue correlacionada con el número real de bayas previamente medido. Esta correlación entre el número de círculo detectados y el número real de bayas en el racimo tuvo una correlación lineal con un R^2 0,64 un error absoluto de 11,2 bayas promedio con segmentación K-means y 11,2 bayas promedio con segmentación Fuzzy C -means que es un ajuste aceptable. Además, el

tiempo de respuesta al generar estos códigos es rápido en comparación con el método manual, un minuto por racimo segmentando con Fuzzy C-means y 15 segundos por racimo segmentando con K-meas.

- Fue posible generar un set de datos de 40 racimos con 12 imágenes por racimo, una cada 30°, con el número de bayas, largo y peso de cada racimo medidos manualmente. El algoritmo implementado generó además área y perímetro de los círculos de cada racimo, generando así un set de datos con información que puede ser usada para entrenar algoritmos basados en técnicas de inteligencia artificial.

8. LITERATURA CITADA

1. Aleixosa, N., Blascob, J., Navarrón F., & Moltób, E. (2002). Multispectral inspection of citrus in real-time using machine vision and digital signal processors, *Computers and Electronics in Agriculture*, 33, 121-137.
2. Brosnan, T., & Sun D.W. (2004). Improving quality inspection of food products by computer vision — A review. *Journal of Food Engineering*, 61, 3-16
3. Cebeci, Z., & Yildiz, F. (2015). Comparison of k-means and fuzzy c-means algorithms on different cluster structures. *Agrárinformatika/journal of agricultural informatics*, 6, 13-23.
4. Diago, M. P., Correa, C., Millán, B., Barreiro, P., Valero, C., & Tardaguila, J. (2012). Grapevine yield and leaf area estimation using supervised classification methodology on RGB images taken under field conditions. *Sensors*, 12, 16988-17006.
5. Diago, M. P., Tardaguila, J., Aleixos, N., Millan, B., Prats-Montalban, J. M., Cubero, S., & Blasco, J. (2015). Assessment of cluster yield components by image analysis. *Journal of the Science of Food and Agriculture*, 95, 1274-1282.
6. Fanizza, G., Lamaj, F., Costantini, L., Chaabane, R., & Grando, M. S. (2005). QTL analysis for fruit yield components in table grapes (*Vitis vinifera*). *Theoretical and Applied Genetics*, 111, 658-664

7. Font, D., Tresanchez, M., Martínez, D., Moreno, J., Clotet, E., & Palacín, J. (2015). Vineyard yield estimation based on the analysis of high-resolution images obtained with artificial illumination at night. *Sensors*, 15, 8284-8301.
8. Gomes, J.F.S. & Leta, F.R. (2012). Applications of computer vision techniques in the agriculture and food industry: A review. *European Food Research and Technology*, 235, 989-1000.
9. González, RC, Woods, RE y Eddins, SL (2009). Utilizando MATLAB®.
10. Hacking, C., Poona, N., Manzan, N., & Poblete-Echeverría, C. (2019). Investigating 2-d and 3-d proximal remote sensing techniques for vineyard yield estimation. *Sensors*, 19, 3652.
11. Liu, S., Marden, S., & Whitty, M. (2013, December). Towards automated yield estimation in viticulture. In *Proceedings of the Australasian Conference on Robotics and Automation, Sydney, Australia (Vol. 24, pp. 2-6)*
12. Millan, B., Velasco-Forero, S., Aquino, A., & Tardaguila, J. (2018). On-the-go grapevine yield estimation using image analysis and boolean model. *Journal of Sensors*, 2018.
13. Mochida, K., Koda, S., Inoue, K., Hirayama, T., Tanaka, S., Nishii, R., & Melgani, F. (2019). Computer vision-based phenotyping for improvement of plant productivity: a machine learning perspective. *GigaScience*, 8, giy153.

14. Nuske, S., Wilshusen, K., Achar, S., Yoder, L., Narasimhan, S., & Singh, S. (2014). Automated visual yield estimation in vineyards. *Journal of Field Robotics*, 31, 837-860.
15. Patel, K.K., Kar, A., Jha, S.N., & Khan, M.A. (2012). Machine vision system: A tool for quality inspection of food and agricultural products, *Journal of Food Science and Technology—Mysore*, 49, 123-141
16. Reis, M. J., Morais, R., Peres, E., Pereira, C., Contente, O., Soares, S., ... & Cruz, J. B. (2012). Automatic detection of bunches of grapes in natural environment from color images. *Journal of Applied Logic*, 10, 285-290.
17. Roscher, R., Herzog, K., Kunkel, A., Kicherer, A., Töpfer, R., & Förstner, W. (2014). Automated image analysis framework for high-throughput determination of grapevine berry sizes using conditional random fields. *Computers and Electronics in Agriculture*, 100, 148-158.
18. Tian, H., Wang, T., Liu, Y., Qiao, X., & Li, Y. (2020). Computer vision technology in agricultural automation—A review. *Information Processing in Agriculture*, 7, 1-19.