

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMIA**



**ESTIMACIÓN DE LA CARGA FRUTAL EN MANZANO cv. 'FUJI' A TRAVÉS
DEL ANÁLISIS DE IMÁGENES DIGITALES**

POR

CONSTANZA ANDREA MEZA ARAYA

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN PARA
OPTAR AL TÍTULO DE INGENIERA
AGRÓNOMA**

CHILLÁN – CHILE

2023

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**

**ESTIMACIÓN DE LA CARGA FRUTAL EN MANZANO cv. 'FUJI' A TRAVÉS
DEL ANÁLISIS DE IMÁGENES DIGITALES**

POR

CONSTANZA ANDREA MEZA ARAYA

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERA AGRÓNOMA.**

**CHILLÁN – CHILE
2023**

Aprobada por:

Profesor Asociado. Richard Bastías I.
Ing. Agrónomo. Mg. Hort., Ph. D

Guía

Profesor Asistente Miguel Garriga C.
Lic. En Biología Mg. Hrt., Dr. Cs.

Asesor

Profesor Asociado Antonio Pinto R.
Ing. Agrónomo. Mg. Eco., Ph. D.

Asesor

Profesor Asociado Sebastián Godoy M.
Ing. Civil Electrónico. Mg. Cs., Ph. D.

Asesor

Profesor Asociado, Guillermo Wells M.
Ing. Agrónomo. M.Sc.

Decano

TABLA DE CONTENIDOS

	Página
Resumen	1
Summary.....	2
Introducción	2
Materiales y Métodos	6
Resultados y Discusión	11
Conclusiones	20
Referencias	20
Apéndice	23

INDICE DE FIGURAS, TABLAS Y ANEXOS

		Página
Figura 1	Procesamiento de imagen para obtener segmentación, donde a) es la imagen original, y b) corresponde a la región de interés.....	8
Figura 2	Diagrama de flujo con umbrales definidos para segmentar frutos de color rojo en árboles de manzanos 'Fuji'	9
Figura 3	Diagrama de flujo con umbrales definidos para segmentar frutos de color verde en árboles de manzanos 'Fuji'	10
Figura 4	Identificación de manzanas rojas a partir de la imagen RGB (a), imágenes en tonos de grises obtenida a partir de la diferencia entre los canales R y G (b), máscara binaria generada por el umbral $R-G > 10$ (c), y los frutos rojos segmentados (d).....	11
Figura 5	Imagen originada a partir de la diferencia de canales R y B (a), máscara de vegetación y frutos generada a partir de un umbral $R-B > 80$ (b), máscara de vegetación generada a partir del umbral $G-R > 0$ (c), máscara final obtenida de la diferencia entre mascarar b y c correspondiente a frutos verdes (d).....	13
Figura 6	Carga frutal estimada en manzanos 'Fuji' en términos de número de frutos por árbol (a) y número de frutos por área de sección transversal de tronco, ASTT (b), para niveles de intensidad de raleo manual del 75 %, 50 % y 0 %.....	15
Figura 7	Carga frutal estimada en manzanos 'Fuji' a través del número de frutos contabilizados por imagen (a) y área expresado en número de pixeles (b) para los niveles de intensidad de raleo manual del 75 %, 50 % y 0 %.....	16
Figura 8	Carga frutal estimada en manzanos 'Fuji' en termino de número de frutos contabilizados por el método del	

	cuadrante (a) e índice AF/AC (b) para los niveles de ajuste del 75 %, 50 % y 0 % de raleo manual.....	17
Tabla 1	Parámetros de regresión lineal para las relaciones entre métodos de estimación de carga frutal.....	19
Apéndice 1	Análisis de perfil de línea roja sobre frutos verdes y hojas (a), y perfil de los valores R,G,B y R-B (b).....	23
Apéndice 2	Coefficiente de variación de los distintos métodos de estimación de carga frutal según niveles de ajuste del 75 %, 50 % y 0 % de raleo manual.....	24

ESTIMACIÓN DE LA CARGA FRUTAL EN MANZANO cv. FUJI A TRAVÉS DEL ANÁLISIS DE IMÁGENES DIGITALES

CROP LOAD ESTIMATION IN 'FUJI' APPLE TREES THROUGH DIGITAL IMAGE ANALYSIS.

Palabras índice adicionales: conteo de frutos, análisis RGB, *Malus domestica* Borkh.

RESUMEN

La determinación de carga frutal es clave para la gestión de prácticas de poda y raleo en huertos de manzano. El objetivo de este trabajo fue evaluar el potencial uso del análisis de imágenes digitales utilizando métodos en el espacio de color RGB para estimar carga frutal en cultivos de manzanos cv. 'Fuji'. Para ello se establecieron tres niveles de carga frutal (alta, media y baja) a través de tres intensidades de raleo manual: 0 %, 50 % y 75 %. Se contabilizó manualmente la carga frutal y se tomaron capturas fotográficas a cada árbol, para posteriormente identificar los frutos utilizando diferencias de canales y umbrales en el espacio de color RGB. Las imágenes fueron sometidas a cuatro métodos: i) conteo digital de los frutos en la imagen a través del software ImageJ; ii) Obtención del área de la máscara binaria; iii) Conteo digital del número de frutos por cuadrante; y iv) cálculo del índice área de fruta por área de cuadrante (AF/AC). El método RGB fue efectivo para discriminar la cantidad de frutos rojos y verdes en la imagen. El método de conteo digital de número de frutos por cuadrantes y del índice AF/AC presentaron la mayor sensibilidad estadística (valor $p=0,0004$ y $0,0005$, respectivamente) para discriminar diferencias de carga frutal en manzanos, mientras que el método de número de frutos por cuadrante presentó la mayor capacidad predictiva ($R^2= 0,91$; $p=0,0001$).

SUMMARY

Determining crop load is crucial for managing of pruning and thinning practices in apple orchards. The study aimed to assess the effectiveness of digital image

analysis using methods in red, green, and blue (RGB) color space methods in estimating crop load in apple cv. 'Fuji'. Three crop load levels (high, medium, and low) were established based on manual thinning intensities of 0%, 50% and 75%, respectively. The crop load was manually-estimated and photographic captures were taken for each tree. Fruits were identified using channel differences and thresholds in the RGB color space.

Four methods were applied to the images: i) digital counting of fruits using ImageJ software; ii) calculation of the area of binary mask; iii) digital counting of fruits per quadrant; and iv) calculation of the fruit area index per quadrant area (AF/AC). The RGB method effectively discriminated red and green fruits in the images. Digital counting of fruits per quadrant and the AF/AC index presented the highest statistical sensitivity (p value = 0.0004 and 0.0005, respectively) in discriminating crop load differences in apple trees. Moreover, the number of fruits per quadrant presented the strongest predictive capacity ($R^2=0.91$; $p=0.0001$). These results suggest that quadrant-based RGB image analysis is a promising method for estimating crop load differences in apple trees. However, further refinement is needed in future research work.

INTRODUCCIÓN

En fruticultura, la carga frutal se define como la cantidad de yemas florales, flores o frutos a dejar por unidad de árbol o área de sección transversal de tronco (ASTT) (Wünsche y Ferguson, 2004). Existen diversas prácticas de manejo que permiten definir la carga frutal a dejar en un huerto, las cuales se basan en la remoción parcial de yemas, flores o frutos, a través de la poda o el raleo químico, mecánico y manual de estos órganos (Dennis, 2000). Estas prácticas de poda o raleo son esenciales en huertos comerciales de especies como el manzano (*Malus domestica* Bokh), ya que repercute directamente sobre la calidad y cantidad de producción. Establecer la carga frutal adecuadamente permite obtener fruta de mayor tamaño y peso, con un mejor desarrollo de color, fruta más firme y mayor contenido de sólidos solubles, ácidos titulable y concentración de materia seca (Mika, 1986; Kumar *et al.*, 2010; Robinson *et al.*, 2016; Serra *et al.*, 2016). Por otra parte, el raleo de flores y frutos

es una práctica fundamental en esta especie para contrarrestar los efectos de la producción alterna o “añerismo”, tendencia natural del manzano donde los árboles presentan una carga frutal muy alta un año (año “on”), lo que tiene un efecto inhibitorio sobre la inducción de futuras yemas florales, y como consecuencia una carga frutal muy baja al año siguiente (año “off”) (Jones *et al.*, 1998; Nilgün *et al.*, 2013; Serra *et al.*, 2016).

Para lograr un manejo de precisión de la carga frutal en huertos de manzanos se requiere de múltiples técnicas, las cuales pueden ser utilizadas en conjunto o por si solas en todo el proceso. Robinson *et al.* (2014) destaca la poda invernal como la primera técnica, en la que es necesario regular en forma precisa las yemas florales a dejar según el número objetivo de unidades productivas (ramas, brindillas o dardos) a considerar por cada árbol. Durante la floración y post-floración la eliminación parcial de flores y frutos (raleo) ayudará a mantener un equilibrio constante entre la fructificación y el desarrollo vegetativo para así maximizar la disponibilidad de carbohidratos hacia los frutos que posteriormente crecerán y serán cosechados durante la estación (Jones *et al.*, 1988). Cabe destacar, que en manzano la intensidad y momento del raleo de flores o frutos dependerá principalmente de la cantidad de frutos que se deseen obtener por árbol según la etapa de desarrollo. En etapas tempranas como son la plena floración, caída de pétalos y frutos pequeños de hasta 20 - 25 mm, es donde se condiciona significativamente el tamaño y calidad de fruta deseada a la cosecha (Chaar y Sánchez, 2010; Schwailler, 1996).

Evaluar la efectividad de los procesos de poda y raleo permite tener un mayor control sobre la gestión de estas labores en el campo, donde el conteo de flores o frutos es una tarea crucial y relevante de realizar cada temporada (Brendon *et al.*, 2019). La práctica de conteo de flores y/o frutos normalmente se basa en estimaciones a nivel de campo de manera visual o manual, resultando en una labor tediosa, demandante de tiempo y que a veces es poco precisa. Algunos métodos comúnmente utilizados se basan en la selección de bloques y del conteo por árbol completo o por ramas; en esta labor se realiza el conteo de botones florales o de frutos pequeños recién cuajados (Salvo *et al.*, 2012). No obstante, este tipo de

métodos sigue siendo laborioso y no siempre preciso y objetivo. Anderson *et al.* (2019) demostraron que la precisión del conteo manual de frutos por parte de operadores disminuye ante un tamaño de muestra más grande, siendo también afectado por el factor tiempo, el mayor tamaño del árbol y la densidad de carga frutal.

En el contexto anteriormente mencionado, el desarrollo y la implementación de tecnologías como la visión artificial basada en imágenes se han convertido en una herramienta útil para la gestión de labores asociadas a los procesos agronómicos, el cual podría ser aplicable a la regulación de carga frutal en huertos de manzano (Vasconez *et al.*, 2019).

La estimación de rendimiento en cultivos utilizando herramientas de precisión basadas en aprendizaje y visión automática han ido en aumento. Ambas tecnologías se encuentran dentro de la inteligencia artificial y tienen como fin obtener resultados en funciones de los objetivos planteados en un huerto a través del análisis de imágenes (Van Klompenburg *et al.*, 2020). Sin embargo, existen diversos factores que pueden influir en la identificación de frutos utilizando imágenes digitales. Entre estos factores se encuentran la condición de luminosidad ambiental, la oclusión y duplicación de los frutos, así como también el tamaño y color de los órganos reproductivos a digitalizar (Zhang *et al.*, 2022; Syal *et al.*, 2013; Patel *et al.*, 2012; Payne *et al.*, 2013; Koirala *et al.*, 2021).

Gongal *et al.* (2016) realizaron un estudio para identificar el número de frutos en árboles de manzano utilizando un método integrado de segmentación mediante espacios de colores HSV (Hue, Saturation, Value) y RGB (Red, Green and Blue), además de algoritmos de transformación circular de Hough (CHT) y análisis de manchas. Para ello, aislaron el árbol del exterior con una estructura tipo túnel integrado con un sistema de sensores (cámara de color y 3D) e iluminación artificial, logrando identificar y segmentar los frutos con una precisión del 82 % respecto al conteo manual. Silwal *et al.* (2014), a través de una metodología similar, lograron identificar manzanas rojas parcialmente visibles y frutos ocluidos y, a través de técnicas de visión automática como reconocimiento de regiones, lograron una precisión del 90 % de identificación de frutos en imágenes digitales. Del mismo

modo, Payne *et al.* (2013), en cultivo de mango (*Mangifera indica* L.) estimaron la carga frutal realizando segmentaciones de píxeles en las imágenes tomadas. Lograron discriminar los frutos del dosel a través del establecimiento de rangos de color entre los canales del espacio RGB y YCbCr. Además, se estableció una segmentación de textura basada en la variabilidad de píxeles que se encuentran adyacentes, logrando una precisión del 91 % del método digital con relación al conteo manual.

En cuanto a la aplicación de este método, Zhou *et al.* (2012), utilizando el espacio de color RGB, desarrollaron un modelo de pronóstico de rendimiento en manzanos 'Gala' en base a variaciones de color en los frutos en diferentes periodos de maduración con una capacidad de predicción de rendimiento entre 58 % y 70 %. En la misma línea, se han desarrollado métodos de segmentación más complejos, como los empleados por Bargoti y Underwood (2016) quienes trabajaron con imágenes para detección y conteo de frutos en manzano a través de algoritmos matemáticos denominados Red Neuronal Convolutiva (CNN) y Percepción de Multicapa (MLP). Dichos algoritmos permiten generar una salida de la segmentación de frutas en píxeles, los que a su vez pueden ser procesados mediante otros algoritmos como transformación divisoria (WS) y transformación del círculo de Hough (CHT) permitiendo detectar y contabilizar frutos individualmente según su relieve y forma. Este método alcanzó una precisión del 83 % en la estimación de rendimiento en huertos de manzanos.

En resumen, en la actualidad existen diferentes métodos para contabilizar la cantidad de frutos en base al análisis de imágenes, utilizando canales de color como RGB, YCbCr y/o algoritmos como CNN, CHT, MLP, entre otros (Smith *et al.*, 2021; Van Klompenburg *et al.*, 2022; Gongal *et al.*, 2015). Estos métodos de análisis de imágenes presentan una interesante proyección para trabajar en técnicas de inteligencia artificial aplicada en la fruticultura y específicamente como herramienta para determinar con mayor precisión la eficacia de las prácticas de regulación de carga frutal que se emplean en los huertos. Si bien se han utilizado métodos en el espacio de color RGB en manzanos de cultivar 'Gala', como método de predicción (Zhou *et al.*, 2012), su aplicación en la industria frutícola chilena es aún incipiente,

por lo que se requiere de estudios locales de validación bajo condiciones de campo, incluyendo otros cultivares comerciales de importancia comercial como 'Fuji', Pink Lady®, entre otros.

HIPÓTESIS

El análisis de imágenes digitales mediante el uso del espacio de color RGB permite estimar la variación de la carga frutal en huertos de manzanos cv. 'Fuji'.

OBJETIVOS

Objetivo general

- Evaluar el uso del análisis de imágenes digitales utilizando métodos en el espacio de color RGB para estimar la carga frutal en huertos de manzanos 'Fuji'.

Objetivos específicos

- Establecer y cuantificar manualmente diferentes niveles de carga frutal en árboles de manzanos en plena producción.
- Digitalizar y analizar imágenes con los diferentes niveles de carga frutal obtenidos bajo condiciones de campo.
- Comparar y relacionar la carga frutal obtenida a través del análisis de imágenes digitales utilizando el espacio de color RGB, vs el método basado en el conteo manual.

MATERIALES Y METODOS

Material vegetal

El ensayo se desarrolló en un huerto de manzano del cultivar 'Fuji' injertado en patrón M9, con una edad de 11 años y plantado en la estación experimental 'El Nogal', de la Universidad de Concepción, campus Chillán, comuna de Chillán, Provincia de Diguillín, Región de Ñuble, Chile (36°35'52.9" S 72°04'54.6" W, 117

m.s.n.m.). El huerto poseía un marco de plantación de 3,5 m entre hilera y 1,2 m sobre hilera, en orientación norte-sur. Los árboles se regaron a través de un sistema por goteo con un caudal de 2 Lh^{-1} .

Establecimiento de los niveles de carga frutal

Se seleccionaron un total de 12 árboles de manzanos de similar vigor con un promedio de carga frutal de 256 frutos por árbol, aproximadamente. A los 70 días antes de cosecha (DAC), a un grupo de cuatro árboles seleccionados al azar (réplicas) se les realizó un ajuste de carga frutal en tres niveles mediante un raleo manual: i) carga alta: se dejaron los árboles sin ralear; ii) carga media: remoción de un fruto en unidades frutales por cada dos frutos contados desde la base hasta la parte alta del árbol (50 % de intensidad de raleo); y iii) carga baja: remoción de tres frutos por cada cuatro frutos contados desde la base del árbol hasta la parte alta (75 % de la intensidad de raleo).

Se estimó el número total de frutos en cada repetición haciendo un conteo manual en los árboles seleccionados. Posteriormente, se midió el diámetro del tronco en cada árbol a una altura de 10 cm desde la unión variedad y portainjerto, utilizando un pie de metro digital (VWR, Radnor, USA), para estimar a partir de este valor el área de sección transversal de tronco (ASTT) con la siguiente ecuación: $ASTT = \pi R^2$, donde R es el radio del árbol.

Captura de imágenes digitales

Posterior al raleo manual de frutos, a cada árbol seleccionado se le tomó una fotografía digital con sus respectivos frutos, utilizando una cámara digital de un teléfono Samsung modelo A50 (Samsung Galaxy, Corea del Sur). Las fotografías fueron capturadas bajo condiciones lumínicas de día nublado debido a la alta proporción de luz difusa. Estas imágenes fueron tomadas en el cuadrante noroeste y en sentido perpendicular a las hileras de los árboles a una distancia de 2,5 m respecto a la hilera.

Las imágenes RGB tomadas fueron almacenadas en formato JPG (Joint Photographic Expert Group).

Procesamiento y análisis de imágenes

Eliminación de interferencia

En una primera etapa se realizó el procesamiento de las imágenes digitales para establecer una segmentación de frutos según la metodología propuesta por Zhou *et al.* (2012). Esta consistió en realizar un recorte de la región de interés, en este caso fue el dosel del árbol con sus respectivos frutos, eliminando los elementos que generan interferencia, tales como ramas de árboles aledaños y zonas del suelo para así obtener la respectivas máscaras (Figura 1).

Figura 1. Procesamiento de imagen para obtener segmentación, donde a) es la imagen original, y b) corresponde a la región de interés.



Discriminación de frutos

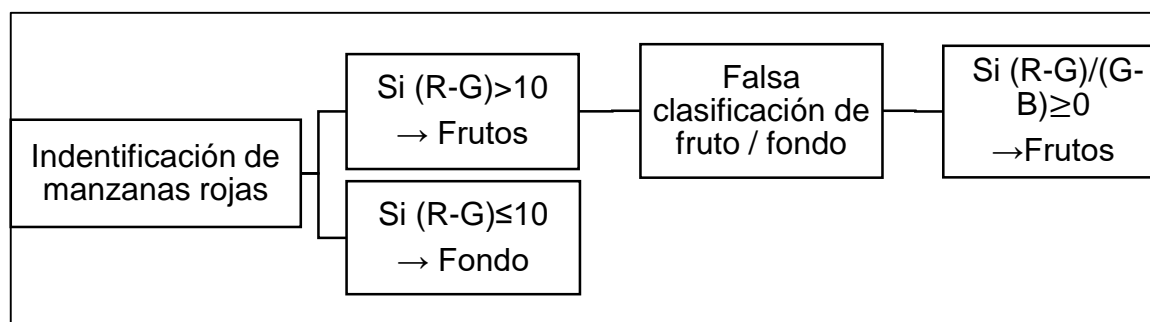
Para la discriminación de frutos se utilizó el algoritmo propuesto por Zhou *et al.* (2012), el cual se basa en el análisis de los canales RGB y que permite la discriminación de frutos a través de su color.

El procesamiento de imágenes comenzó con la extracción del valor de los componentes rojo (R), verde (G) y azul (B). A partir de esta extracción se obtuvieron las matrices de cada componente, las cuales tienen un tamaño determinado de píxeles, lo que a su vez depende del recorte de la región de interés previamente identificado. Los píxeles se encuentran distribuidos en un rango de visualización predeterminado que va de 0 a 255. De esta forma, la Figura 2 muestra un diagrama

para la discriminación de manzanas rojas la cual se basa en la diferencia entre los canales rojo (R) y verde (G). En base a esta diferencia, se analizó el valor de los píxeles utilizando la herramienta “región de píxeles”. Mediante este análisis se identificó que los valores cercanos a 0 no correspondían a frutos. Se realizó un ajuste de contraste modificando el rango de visualización y se estableció un umbral de $R-G > 10$ para generar una máscara binaria. Esto significa que, para todos los píxeles que se encontraban sobre el valor 10 se restablecieron a 1 (blanco), mientras que los píxeles con valores < 10 se restablecieron a 0 (negro).

Posteriormente y para reducir el área falsamente segmentada como frutos, se obtuvieron los canales del producto de la máscara binaria ($R-G > 10$) y la imagen original, permitiendo aplicar la relación $(R-G) / (G-B)$, donde se estableció el umbral $(R-G) / (G-B) > 0$, permitiendo crear una nueva imagen binaria con un área reducida de elementos que no corresponden a frutos.

Figura 2. Diagrama de flujo con umbrales definidos para segmentar frutos de color rojo en árboles de manzanos ‘Fuji’.

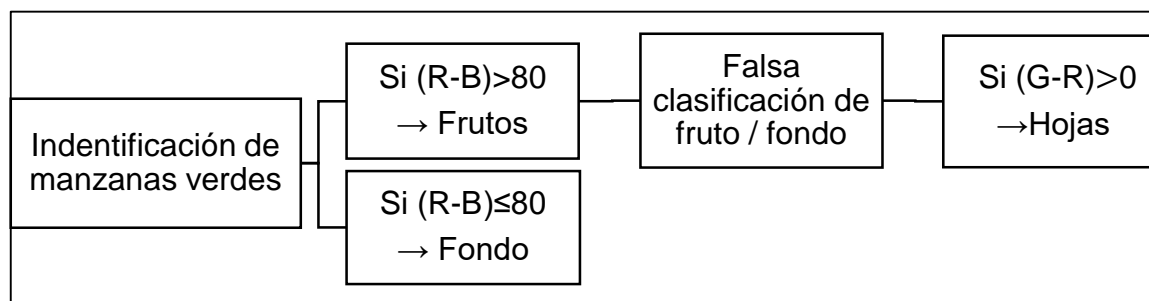


Considerando que en la imagen existen frutos de poca coloración roja o inmaduros, resultó necesario discriminar las manzanas de color verde a través de la determinación de una diferencia de color entre los canales R y B (Figura 3). El umbral se definió a partir de un análisis previo de los valores RGB y R-B en frutos de color verde. De esta forma, para la diferencia entre los canales R y B se estableció un umbral de 80 que permitió segmentar los frutos de color verde.

A partir de este análisis se obtuvieron los canales G, R, y B del producto de la máscara binaria ($R-B$) y la imagen original para eliminar la interferencia del área foliar sobre la discriminación de frutos de color verde, aplicando posteriormente la

diferencia entre los canales G y R. Se estableció un nuevo umbral de $G-R > 0$ para obtener el área vegetativa de la imagen que corresponde a brotes y hojas. A través de la diferencia entre las máscaras $R-B$ y $G-R$ se logró segmentar los frutos de color verde en la imagen.

Figura 3. Diagrama de flujo con umbrales definidos para segmentar frutos de color verde en árboles de manzanos 'Fuji'.



Finalmente se realizó una operación lógica OR entre las matrices de las máscaras binarias de frutos rojos y verdes para cuantificar el área frutal total de cada imagen.

Estimación de la carga frutal

Luego de adquiridas y procesadas las imágenes en el espacio RGB, se estimó la carga frutal a través de cuatro métodos: i) Conteo digital de cada uno de los frutos que resultaron visibles en la imagen a través del software ImageJ versión 1.53e; ii) Obtención del área de la máscara binaria para el dosel completo del árbol, expresado en número de píxeles; iii) Conteo digital del número de frutos por cuadrante (401x401x3 uint8); y iv) Cálculo del índice AF/AC, donde AF es el área frutal segmentada desde un cuadrante binario de 401x401 píxeles (AC).

Análisis de la información y procesamiento estadístico

El procesamiento y análisis de imágenes en canales RGB se realizó a través del software Matlab versión R2023a (Mathworks Inc., EE. UU.).

Los niveles de carga frutal, tanto estimado en forma manual como a través de análisis de imágenes, fueron sometidos a un análisis de varianza (ANOVA) con un nivel de significancia del 95 %, previo cumplimiento de los supuestos de normalidad y homogeneidad a través de las pruebas de Shapiro-Wilks y Levene, respectivamente. Los datos de las variables que no cumplieron ambos supuestos


fueron transformados mediante escores normales. Para la separación de medias se usó el test de comparación múltiple de Duncan al 95 %. Posteriormente, se estimó el coeficiente de determinación entre los valores de carga frutal estimados por el método de análisis de imágenes vs. el manual, a través de un análisis de regresión con un nivel de significancia del 95 %. Todos los análisis estadísticos se realizaron a través del software Infostat (Di Rienzo *et al.*, 2007, Argentina).

RESULTADOS Y DISCUSIÓN

Discriminación de frutos

Para la identificación de manzanas rojas, como se observa en la Figura 4, los umbrales establecidos durante el proceso de segmentación permitieron detectar los frutos rojos en el perfil del dosel. Tal como se aprecia, a partir de la imagen original (Figura 4a), la diferencia entre los canales rojo y verde permitió crear una nueva imagen en tonos de grises (Figura 4b), y sobre esta imagen se estableció el umbral de $R-G > 10$, dando como resultado la máscara binaria (Figura 4c) que permite observar el área segmentada correspondiente a frutos rojos (Figura 4d).

Figura 4. Identificación de manzanas rojas a partir de la imagen RGB (a), imágenes en tonos de grises obtenida a partir de la diferencia entre los canales R y G (b), máscara binaria generada por el umbral $R-G > 10$ (c), y los frutos rojos segmentados (d).



En algunas imágenes un área importante de la segmentada correspondía a parte del suelo y/o ramas. En este sentido, el umbral $(R-G)/(G-B) > 0$ logró disminuir esta

área, permitiendo obtener una nueva máscara con un área reducida de píxeles que no correspondían a frutos rojos (Figura 4).


Por otro lado, el umbral definido $R-B > 80$ permitió segmentar en su totalidad los píxeles de frutos verdes expuestos (Figura 5), aunque un área segmentada importante correspondía a hojas (Figura 5b). En este sentido, las diferencias entre los canales G-R, permitió la extracción del área vegetativa creando una nueva máscara binaria donde todos los píxeles segmentados correspondían a hojas (Figura 5c). Esta discriminación del área vegetativa respecto a los frutos verdes de la imagen fue posible gracias a que, tal como se observa en la descripción de los canales del Apéndice 1, algunas manzanas de color verde presentaban píxeles con mayor valor del canal rojo que del canal verde, especialmente aquellas que se encontraban expuestas (Apéndice 1).

La nueva máscara vegetativa, a diferencia de la anterior ($R-B > 80$), permitió crear la máscara de frutos verdes tras la eliminación del área vegetativa. Como se observa en la Figura 5d, el procedimiento para la segmentación de manzanas verdes logró discriminar aquellas manzanas que se encontraban expuestas en el perfil del árbol, no así aquellas que se encontraban sombreadas por hojas.

Los resultados de imágenes obtenidas en la discriminación de frutos rojos y verdes (Figura 4 y 5) son similares a los obtenidos por Zhou *et al.* (2012). Esto es relevante, si se considera que en el presente estudio las fotografías fueron tomadas en campo en forma simple y con mucha interferencia, dada por la vegetación, suelo, entre otros aspectos. En cambio, Zhou *et al.* (2012), en su investigación contemplaron el uso de esferas blancas y rojas en la parte superior del árbol como calibradores, además de una cortina blanca detrás de los árboles objetivos en la toma de imágenes. Los resultados de este estudio demostrarían que, el uso del método empleado en el espacio de color RGB permite discriminar píxeles que son de interés, en este caso aquellos que corresponden a frutos rojos y verdes, aun cuando las imágenes que se tomaron no son de la calidad deseada para este tipo de estudio, lo que obligó a una serie de análisis previos, partiendo con la identificación de los valores de cada canal en los píxeles que forma parte de la

imagen digital, hasta establecer los diferentes umbrales para crear máscaras con sus respectivas regiones de interés.

Figura 5. Imagen originada a partir de la diferencia de canales R y B (a), máscara de vegetación y frutos generada a partir de un umbral $R-B > 80$ (b), máscara de vegetación generada a partir del umbral $G-R > 0$ (c), máscara final obtenida de la diferencia entre máscaras b y c correspondiente a frutos verdes (d).



Al respecto se ha indicado que identificar frutos en condiciones naturales basándose únicamente en el espacio de color de las imágenes es un proceso que está sujeto a múltiples variables (Fu *et al.*, 2020). En el presente estudio, a pesar de que las condiciones de iluminación fueron óptimas, otras variables como el sombreado, oclusión de frutos, variación de color en las manzanas y posición de la fruta en el dosel influyeron en los resultados. Estos factores interfieren en diferentes grados en el éxito de poder identificar y segmentar el 100 % de los frutos existentes en el árbol. En este sentido, algunos trabajos postulan la necesidad de incorporar otras características además del color, como textura, tamaño y/o forma en el análisis de imágenes, los cuales se han estudiado en otros cultivos frutales y que se podrían incluirse en futuros trabajos para la estimación de carga frutal en manzanos. (Linker *et al.*, 2012; Gatica *et al.*, 2013; Hazra *et al.*, 2013).

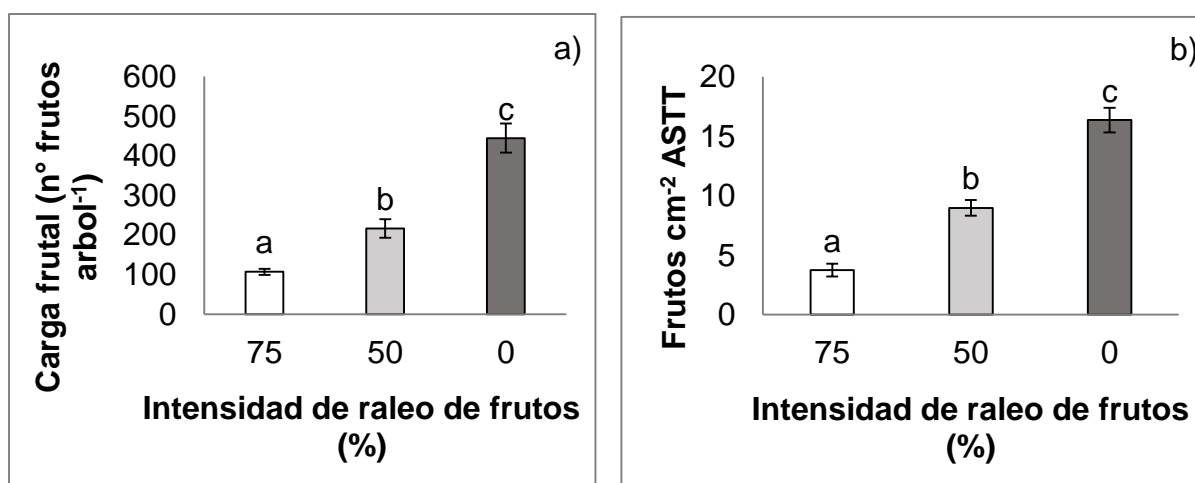
Determinación de niveles de carga frutal

El número de frutos por árbol mostró diferencias significativas ($p \leq 0,05$) para las diferentes intensidades de raleo establecidas (0 %, 50 % y 75 %) (Figura 4a), al igual que para el número de frutos por ASTT que, de acuerdo con la literatura, para el cultivar 'Fuji' la carga frutal recomendada es de 5 frutos ASTT⁻¹ (Robinson, 2008). Lo anterior estaría indicando que los tratamientos de raleo de 50 % y 0 % significaron una sobre carga frutal importante para este cultivar, ya que estos valores estuvieron cercanos a 9 y 16 frutos ASTT⁻¹, respectivamente (Figura 6b).

El número de frutos contados por imagen a través de ImageJ no permitió discriminar en forma significativa ($p = 0,0688$) las diferencias de carga frutal entre los tratamientos de raleo (Figura 7a). De igual modo, no lo hizo el análisis de área expresado en número de píxeles ($p = 0,2076$) (Figura 7b).

La baja sensibilidad de ambos métodos de análisis de imagen para detectar las diferencias de carga frutal se debe a la alta variabilidad estadística que mostraron con relación al conteo manual (Apéndice 2). El coeficiente de variación (CV) de los métodos de conteo manual por árbol y ASTT fueron, promediando todos los tratamientos de carga frutal, del orden de 17,5 % y 18,9 %, respectivamente. En tanto, para los métodos de análisis de imágenes por ImageJ y de área (n° píxeles) los valores de CV fueron de 36,8 % y 51,4 %, respectivamente.

Figura 6. Carga frutal estimada en manzanos 'Fuji' en términos de número de frutos por árbol (a) y número de frutos por área de sección transversal de tronco, ASTT (b), para niveles de intensidad de raleo manual del 75 %, 50 % y 0 %.



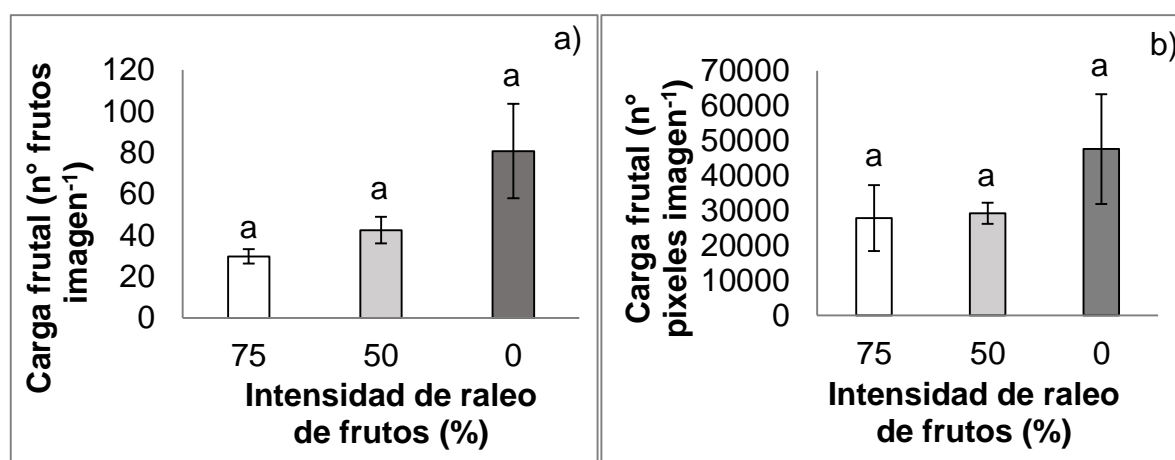
Estas diferencias de variabilidad estadística se deben a la posición de los frutos en el dosel y la cantidad de frutos que logran ser capturados por la cámara desde la posición en que se tomaron las fotografías. Bulanon y Burks (2009), trabajando en cultivo de cítricos, demostraron que, adicionar técnicas de visualización al reconocimiento de frutos, como múltiples vistas de la copa del árbol desde diferentes ángulos, pueden mejorar la visibilidad de los frutos de un 50 % a un 90 %, aproximadamente. Además, en este estudio los niveles de carga frutal con los que se trabajaron fueron de normal a muy alta (Figura 6), lo que conlleva a que una gran cantidad de frutos se encuentren ocultos y haciéndolos difícilmente detectables. En este sentido, Stajniko *et al.* (2009), demostraron que los algoritmos de detección poseen una alta tasa de reconocimiento cuando la carga frutal se encuentra entre los valores de 15 y 42 frutos por árbol, lo que significa valores muy por debajo de los valores de carga frutal utilizada para el presente estudio (Figura 6a).

Otro factor que explica esta alta variabilidad estadística de los métodos de imágenes tiene está relacionado al desarrollo de color de los frutos. En el presente estudio, las imágenes fueron tomadas 70 DAC, lo que implica que parte importante de los frutos visibles en el dosel se encontraban todavía inmaduros, es decir, sin intensidad de coloración roja propia del cultivar de manzana 'Fuji'. Estudios similares han demostrado que los métodos de reconocimiento tienen un mayor grado de precisión cuando la coloración del fruto es contrastante con el color verde del dosel del árbol; cuando los frutos son de color verde, algunas hojas se reconocen erróneamente debido a que poseen una intensidad de color similar en el espacio de color RGB (Yu *et al.*, 2021).

En este estudio se determinó que la cantidad de frutos segmentados como píxeles fue mayor a medida que la carga frutal de la imagen era menor (Figura 7). Sin embargo, la no uniformidad en el color de los frutos dificultó el procesamiento de las imágenes. Por otra parte, los frutos verdes dificultaron su diferenciación de hojas, brotes del dosel del árbol y malezas presentes en el suelo, ya que estos últimos elementos compartieron la misma información de color (valores R, G y B) al momento de detectar los frutos de color verde. Estos resultados coinciden con lo

descrito por Silwal *et al.* (2014) al trabajar en manzanas de los cultivares ‘Jazz’ y ‘Fuji’. En este caso, la fruta detectada por el método de transformación del círculo de Hough (CHT) y el análisis de manchas, al ser procesada por el espacio de color RGB obtuvieron un 8,2 % de falsos negativos, debido a que los umbrales establecidos para segmentar no permitieron filtrar restos de hojas y madera con similar información de color que los frutos.

Figura 7. Carga frutal estimada en manzanos ‘Fuji’ a través del número de frutos contabilizados por imagen (a) y área expresado en número de píxeles (b) para los niveles de intensidad de raleo manual del 75 %, 50 % y 0 %.

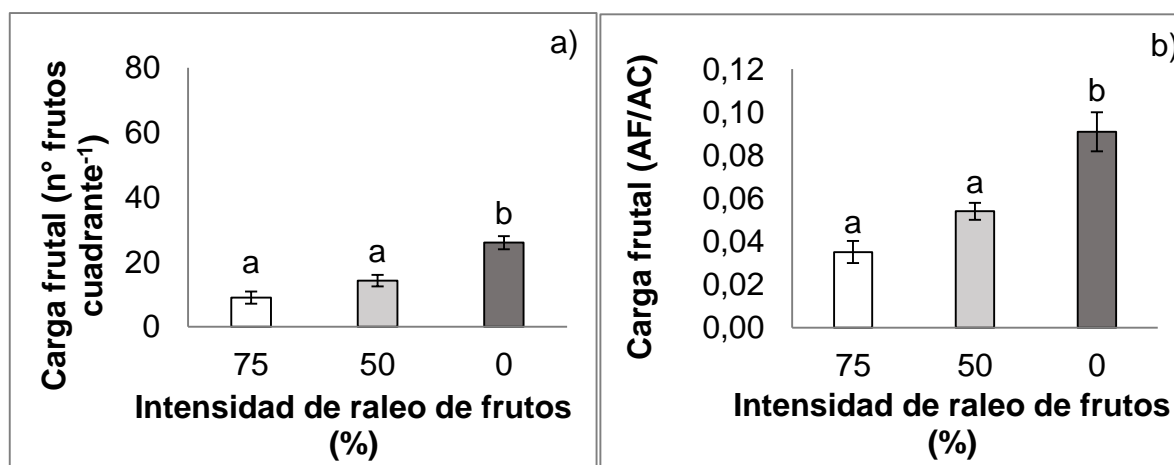


Los métodos de conteo digital del número de frutos por cuadrantes y del índice AF/AC presentaron una mayor sensibilidad estadística ($p=0,0004$ y $p=0,0005$, respectivamente), pero esta discriminación fue efectiva solo cuando se comparó la carga alta (0 % de raleo) con la carga media (50 % de raleo) y baja (75 % de raleo), no encontrando diferencias significativas en el conteo para carga media y baja (Figura 8). Lo anterior se debe a que al establecer el conteo de frutos por cuadrantes dentro del dosel del árbol significa una menor proporción de frutos ocluidos por hojas, ramas y otros frutos presentes en la imagen, lo cual aumenta la eficiencia del procesamiento. Esta diferencia (variación estadística) se ve reflejado en el CV, que en este caso fue del orden de un 27,3 % (Apéndice 2). Algunos trabajos han demostrado que el conteo de cantidad de flores o frutos por métodos de cuadrantes han sido efectivos para estimar la carga frutal bajo condiciones de campo. Zaman

et al. (2010) estimó el rendimiento de arándano (*Vaccinium* sp.) mediante imágenes utilizando como base un cuadrante de 0,5 x 0,5 m a través de un sistema automatizado, encontrando una correlación significativa entre el porcentaje de píxeles de color azul (frutos de arándanos) y el rendimiento real de frutos.

Cabe destacar que aun cuando estos métodos de cuadrantes presentaron una capacidad mayor para detectar diferencias de carga frutal, no fueron capaces de detectar diferencias entre los niveles de carga media y baja. Lo anterior podría deberse a un efecto de vigor de planta. En general, una menor carga frutal indica un mayor desarrollo de hojas en el segundo flash de crecimiento de brotes del manzano, lo cual podría significar una mayor interferencia al momento de identificar los frutos (Lenz, 1977; Palmer *et al.*, 1991).

Figura 8. Carga frutal estimada en manzanos ‘Fuji’ en término de número de frutos contabilizados por el método del cuadrante (a) e índice AF/AC (b) para los niveles de ajuste del 75 %, 50 % y 0 % de raleo manual.



Relación de estimación de carga frutal por método manual vs imagen

A través del análisis de regresión se determinó que la relación entre el número de frutos estimados por el método de conteo digital a través de ImageJ y el número de frutos por árbol permitió estimar significativamente la carga frutal (Tabla 2). Este método permitió explicar el 64 % de la variación de la carga en manzanos ‘Fuji’. Este valor es menor con relación a la investigación previa realizada por Payne *et al.* (2013) en cultivo de mango (*Mangifera indica* L.), donde a través de análisis de regresión lineal, obtuvieron coeficientes de determinación del 0,81 y 0,93 entre el

conteo de frutos por imagen y número de frutos por árbol según la posición de toma de imagen. Esto demuestra la importancia de la distribución y visibilidad de los frutos en el dosel de la planta al momento del conteo, ya que, en cultivos como el mango, una proporción considerable de los frutos se encuentra colgando bajo el dosel, el cual los hace visibles desde los diferentes puntos de toma de imagen.

El método de número de píxeles por imagen no explicó significativamente la variación de la carga frutal en manzanos 'Fuji', $p > 0,05$ (Tabla 2). La metodología en la toma de imágenes explicaría en cierto grado esta escasa relación. De acuerdo con estudios de Gongal *et al.* (2018) y Aggelopoulou *et al.* (2010), el fondo de la imagen influye sobre esta precisión. Un fondo negro o blanco permite asegurar el contraste entre los órganos de la planta que son el objetivo del estudio, además, permite un mayor control sobre la iluminación evitando el efecto de interferencia de la luz. Por otro lado, el momento de adquisición de imagen es otro factor por considerar. En este contexto, Zhou *et al.* (2012) demostraron que mientras más cercano a la época de cosecha se toma la imagen puede significar un aumento en el coeficiente de correlación de 0,80 a 0,85, debido a una mayor eficiencia del procesamiento de la imagen por la mayor uniformidad en el color de los frutos.

Tabla 1. Parámetros de regresión lineal para las relaciones entre métodos de estimación de carga frutal.

Variable		Modelos	Parámetros de regresión			Valor p
Dependiente	Independiente		a	b	R ²	
Carga frutal (n° frutos árbol ⁻¹)	Carga frutal (n° frutos imagen ⁻¹)	Y= aX+b	3,63	70,46	0,64*	0,0018
Carga frutal (n° frutos árbol ⁻¹)	Carga frutal (n° píxeles imagen ⁻¹)	Y= aX+b	0,004	122,21	0,29 ^{ns}	0,0724
Carga frutal (n° frutos árbol ⁻¹)	Carga frutal (n° frutos cuadrantes ⁻¹)	Y= aX+b	17,90	-38,07	0,91*	0,0001

Carga frutal (n° frutos arbol ⁻¹)	Carga frutal (AF/AC)	Y= aX+b	4,63	-22,39	0,65*	0,0015
---	-------------------------	---------	------	--------	-------	--------

El método de número de frutos por cuadrantes presentó el valor más alto y significativo en cuanto a su capacidad de estimar la variación de la carga frutal ($R^2=0,91$; Tabla 2), seguido por el índice AF/AC ($R^2= 0,65$). Estos resultados demuestran que el uso del cuadrante facilitó segmentar y detectar los frutos que se encontraban en las imágenes en una menor área de trabajo, permitiendo con ello reducir los falsos positivos. La reducción de falsos positivos se debe a que con el método del cuadrante se descarta la interferencia que se genera en la imagen, por efecto del suelo, cielo, malezas, entre otros, los que alteran el valor real de área correspondiente a frutos, por lo que aumenta la precisión en el proceso de segmentación. Además, este método permitió estandarizar la uniformidad de las manzanas al establecer una relación entre el área frutal que fue segmentada y el área del cuadrante que fue establecido según número de filas y columnas de la imagen.

CONCLUSIONES

1. El método RGB es una técnica potencial para estimar diferencias de carga frutal en manzano cuando las imágenes originales presentan interferencia por el suelo, vegetación y distinta intensidad de color de los frutos.
2. Los métodos en que se utiliza la identificación digital de fruta por cuadrantes y de índice de área de frutos por el área de cuadrante (AF/AC) son más efectivos para determinar los niveles de carga frutal en manzanos, siendo el método de conteo digital por cuadrante el que tuvo la mayor capacidad predictiva.
3. Para mejorar la precisión del método basado en análisis de imágenes en el espacio de color RGB, en futuros trabajos será necesario contrarrestar las variables del huerto que dificulten el procesamiento de las imágenes al momento de su adquisición (suelo, vegetación, iluminación), además de adicionar algoritmos que permiten llevar a cabo otras técnicas de detección complementarias como textura, forma, diámetro de frutos, entre otros.

REFERENCIAS

1. Aggelopoulou, A., D. Bochtis, and G. Nanos. 2010. Yield prediction in apple orchards based on image processing. *Precision agr.* 12(3): 448 – 456.
2. Anderson, N., J. Underwood, M. Rahman, A. Robson and K. Walsh. 2019. Estimation of fruit load in mango orchards: tree sampling consideration and use of machine vision and satellite imagery. *Precision agr.* 20(4): 823 – 839.
3. Bargouti, S. and J.P. Underwood. 2016. Image segmentation for fruit detection and yield estimation in apple orchards. *J. Field Robot.* 34(6): 1039 – 1060.
4. Bendron, A., A. Serra, and S. Musacchi. 2019. Optimizing crop load for new apple cultivar: “WA38”. *Agronomy.* 9(2): 1 – 20.
5. Bulanon, D., and T. Burks. 2009. Improving fruit detection for robotic fruit harvesting. *Acta. Hort.* 824: 329 – 336.
6. Chaar, J. E. y E. E. Sánchez. 2010. Efectos de la carga frutal y del ambiente lumínico en ciruelo D’Agen (*Prunus domestica* L.). *Rev. FCA UNCuyo.* 42(1): 125 – 133.
7. Dennis, Jr. 2000. The history of fruit thinning. *Plant growth regulation.* 31: 1 – 16.
8. Fu, L., F. Gao, J. Wu, R. Li, M. Karkee and Q. Zhang. 2020. Application of consumer RGB-D cameras for fruit detection and localization in field: A critical Review. *Comput. Electron. Agric.* 177: 1 – 12.
9. Gatica, G., S. Best, J. Ceroni and G. Lefranc. 2013. Olive fruits recognition using neural networks. *Proc. Compt. Sc.* 17: 412 – 419.
10. Gil, G. 2000. *Fruticultura – La producción de fruta.* (3ª. Ed). Ediciones UC. Santiago, Chile.
11. Gongal, A., M. Karkee and S. Amatya. 2018. Apple fruit size estimation using a 3D machine vision system. *Inf. Processing in agric.* 5: 498 – 503.
12. Gongal, A., S. Amatya and M. Karkee. 2015. Sensors and system for fruit detection and localization: A review. *Comput. Electron. Agric.* 116: 8 – 9.
13. Gongal, A., A. Silwal, S. Amatya, M. Karkee, Q. Zhang and K. Lewis. 2016. Apple crop-load estimation with over-the-row machine vision system. *Comput. Electron. Agric.* 120: 26 – 35.

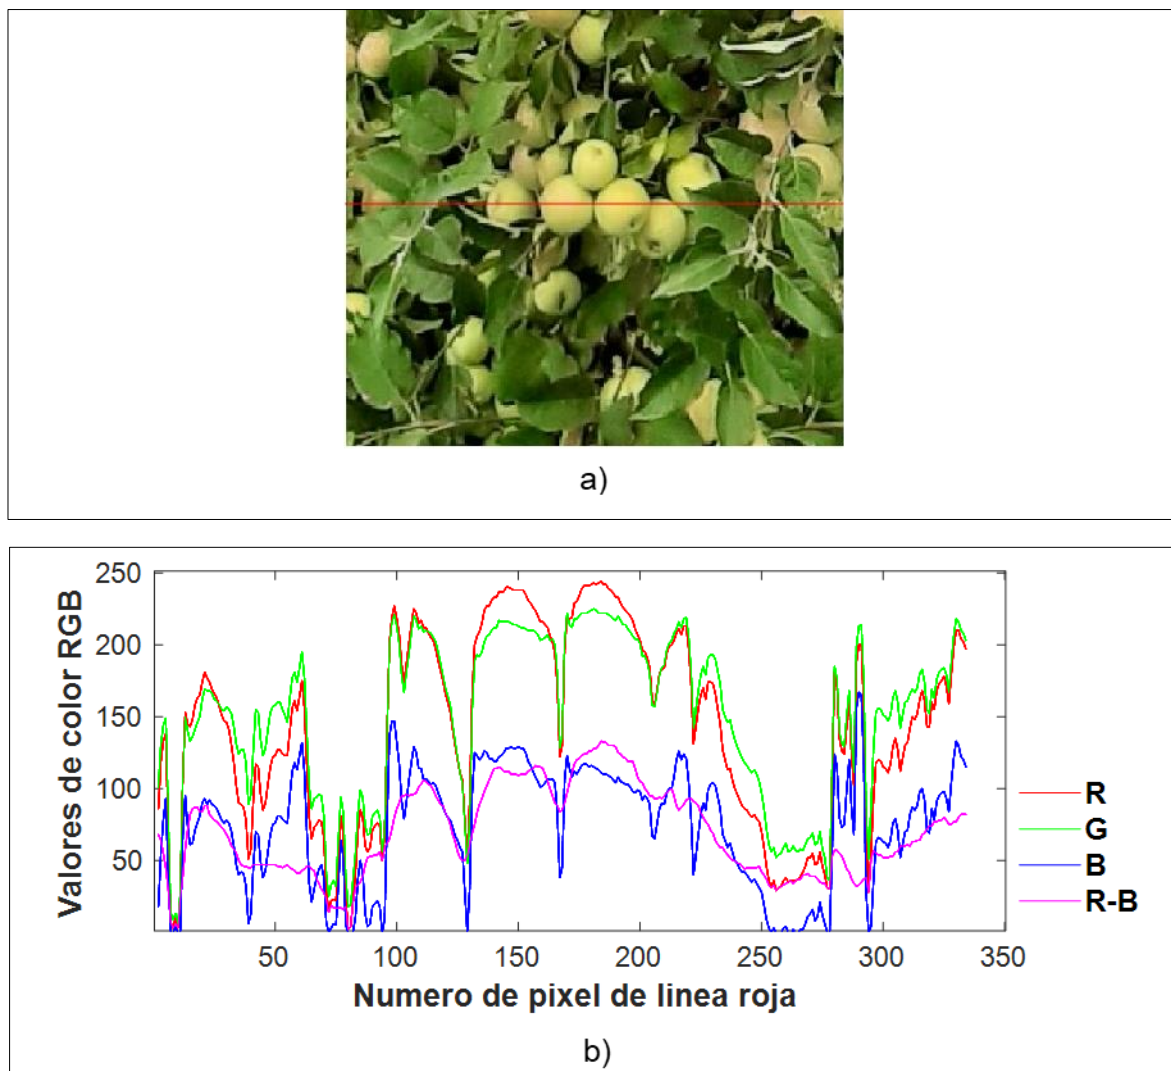
14. Hartmann, W., and M. Neumüller. 2009. *Breeding Plantation Tree Crops: Temperate Species*, Springer. New York.
15. Hazra, A., K. Deb, S. Kundu and P. Hazra. 2013. Shape oriented feature selection for tomato plant identification. *Int. J. Comput. Appl. Techol. Res.* 2(4): 449 – 454.
16. Jones, K., S. Bound and P. Miller. 1998. *Crop regulation of pome fruit in Australia*. Tasmanian institute of agricultural research. Tasmania, Australia.
17. Koirala, A., K. Walsh and Z. Wang. 2021. Attempting to Estimate the Unseen—Correction for Occluded Fruit in Tree Fruit Load Estimation by Machine Vision with Deep Learning. *Agronomy*. 11(2): 1 – 20.
18. Kumar, M., V. Rawat, J. Rawat and Y. Tomar. 2010. Effect of pruning intensity on peach yield and fruit quality. *Scia. Hort.* 125(3): 218 – 221.
19. Lenz, F. 1977. Einfluß der drucht auf photosynthese und atmung. *Z. Pflanzenemähr. Bodenkd.* 140: 51 – 61.
20. Linker, R., O. Cohen and A. Naor. 2012. Determination of the number of green apples in RGB images recorded in orchards. *Comput. Electron. Agric.* 81: 45 – 57.
21. Mika, A. 1986. Physiological response of fruit trees to pruning. pp: 337-378. In: J. Janick (Ed). *Horticultural Review*. John Wiley & sons, Ltd. USA.
22. Nilgün, A., F. Koyuncu and E. Atay. 2013. Relative Susceptibility of Selected Apple Cultivars to Alternate Bearing. *J. Biol. Environ. Sci.* 7(20): 81 – 86.
23. Palacios, F., G. Bueno, J. Salido, M. Diago, I. Hernández and J. Tardaguila. 2020. Automated grapevine flower detection and quantification method based on computer vision and deep learning from on-the-go imaging using a mobile sensing platform under field conditions. *Comput. Electron. Agric.* 178: 1 – 13.
24. Palmer, J., Y. Cai and Y. Edjamo. 1991. Effect of part-tree flowers thinning on fruiting vegetative growth and leaf photosynthesis in 'Cox's Orange Pippin' apple. *J. Hort. Sci.* 66(3): 319 – 325.
25. Patel, H., R. Jain and M. Joshi. 2012. Automatic segmentation and yield measurement of fruit using shape analysis. *IJCSE.* 45 (7): 19 – 24.
26. Payne, A., K. Walsh, P. Subedi and D. Jarvis. 2013. Estimation of mango crop yield using image analysis – segmentation method. *Comput. Ind.* 91: 57 – 64.

27. Pflanz, M., R. Gebbers and M. Zude. 2016. Influence of tree-adapted flower thinning on apple yield and fruit quality considering cultivars with different predisposition in fructification. *ActaHort.* 1130: 605 – 612.
28. Robinson, T. 2008. Crop load management of new high-density apple orchards. *NY Fruit Qtly.* 16(2): 3 – 7.
29. Robinson, T., L. Domínguez and F. Acosta. 2016. Pruning strategy affects fruit size, yield and biennial bearing of ‘Gala’ and ‘Honeycrisp’ apple. *Acta Hort.* 1130: 257 – 263.
30. Schwailler, P. 1996. Apple thinning guide. Great lakes publishing. Sparta, Michigan.
31. Serra, S., R. Leisso, L. Giordani, L. Kalcsits and S. Musacchi. 2016. Crops load influences fruit quality, nutritional balance and return bloom in ‘Honeycrisp’ apple. *HortScience.* 51(3): 236 – 244.
32. Silwal, A., A. Gongal and M. Karkee. 2014. Identification of red apples in field environment with over the row machine vision system. *Agric Eng Int: CIGR e-Journal.* 16(4): 66 – 75.
33. Smith, M., L. Smith and M. Hansen. 2021. The quiet revolution in machine vision - a state-of-the-art survey paper, including historical review, perspectives, and future directions. *Comput. Ind.* 130: 1 – 10.
34. Syal, A., D. Garg and S. Sharma. 2013. A survey of computer vision methods for counting fruits and yield prediction. *IJCSE.* 2(6): 346 – 350.
35. Van Klompenburg, T., A. Kassahun and C. Catal. 2020. Crop yield prediction using machine learning: A systematic literature review. *Comput. Electron. Agric.* 177: 1 – 18.
36. Vasconez, J., G. Kantor and F. Cheein. 2019. Human-robot interaction in agriculture: a survey and current challenges. *Biosyst. Eng.* 179: 35 – 48.
37. Verma, P., S. Sharma, N.C. Sharma and N. Chauhan. 2022. Review on crop load management in apple (*Malus x domestica* Borkh.). *J. Hort. Sci. Bio.* 98(3): 299 – 321.
38. Yu, L., J. Xiong, X. Fang, Z. Yang, Y. Chen, X. Lin and S. Chen. 2021. A litchi fruit recognition method in a natural environment using RGB-D images. *Bio. Eng.* 204: 50 – 63.

39. Zaman, G., K. Swain, A. Schumann and D. Percival. 2010. Automated low-cost yield mapping of wild blueberry fruit. *Applied Eng. In Agric.* 26(2): 225 – 232.
40. Zhang, X., A. Toudeshki, R. Ehsani, H. Li, W. Zhang and R. Ma. 2022. Yield estimation of citrus fruit using rapid image processing in natural background. *Smart Agr. Tech.* 2: 1 – 12.
41. Zou, H. L. Damerow, Y. Sun and M. Blanke. 2012. Using colour features of cv. 'Gala' apple fruit in orchard in image processing to predict yield. *Prec. Agric.* 13: 568 – 580.

APÉNDICE

Apéndice 1. Análisis de perfil de línea roja sobre frutos verdes y hojas (a), y perfil de los valores R, G, B y R-B (b).



Apéndice 2. Coeficiente de variación de los distintos métodos de estimación de carga frutal según niveles de ajuste del 75%, 50% y 0% de raleo manual.

Intensidad de raleo	Carga frutal					
	n° fruto imagen ⁻¹	n° frutos cuadrante ⁻¹	n° pixeles imagen ⁻¹	AF/AC	n° frutos árbol ⁻¹	Frutos cm ² ASTT
75 %	23,3 %	41,6 %	67,8 %	29,1 %	14,4 %	29,4 %
50 %	30,4 %	24,6 %	20,6 %	14,4 %	21,6 %	14,8 %
0 %	56,7 %	15,7 %	65,9 %	19,9 %	16,6 %	12,6 %
Promedio	36,8 %	27,3 %	51,4 %	21,1 %	17,5 %	18,9 %