



Doctorado en Ciencia Aplicada

Jhon Jairo Vega Diaz

**Innovación tecnológica para la reducción de la heterogeneidad del
aguacate "Hass" cosechado para exportación**

**Innovación tecnológica para la reducción de la heterogeneidad del
aguacate "Hass" cosechado para exportación**

Jhon Jairo Vega Diaz

Documento presentado como requisito para optar por el título de Doctor en
Ciencia Aplicada

Directores:

Codirector Temático: Phd. Sergio Alejandro Ojuela Vargas

Codirector Metodológico: Phd. Andres Ignacio Hernández Duarte

Codirector Metodológico: Phd. Rafael Maria Gutierrez Salamanca

Doctorado en Ciencia Aplicada

Universidad Antonio Nariño

Bogotá D.C.

2020

Prefacio

Esta investigación fue motivada por el deseo de aportar avances tecnológicos a los productores colombianos, un sector que históricamente es de los más desvalidos en nuestro país. En el proceso de priorización se escogió el cultivo de aguacate "Hass". Este cultivo tiene un potencial exportador por su demanda internacional y las áreas disponibles para su siembra, además, es un cultivo que puede ser manejado por pequeños y medianos productores, de tal forma que, si se optimiza un proceso de exportación se impactaría un buen porcentaje de la población agrícola, y permitiría reducir las brechas económicas en este sector.

En el análisis de las brechas tecnológicas se evidenció que el proceso de cosecha no ha sido investigado a profundidad y en este punto las pérdidas que se producen son asumidas por el eslabón más débil de la cadena, que es el productor. Por tanto, esta investigación busca que nuestro productor optimice sus ingresos en el proceso de exportación, por tanto, se realizó un proceso de desarrollo tecnológico que incorporó metodologías como evaluaciones del nivel de madurez tecnológica (TRL) y la teoría para resolver problemas de inventiva (TRIZ), estas metodologías permitieron consolidar una propuesta patentable. En el presente documento se demuestra la viabilidad del método en un entorno relevante, que predice si un fruto de aguacate "Hass" en el árbol está en el momento óptimo de cosecha, usando procesamiento de imágenes.

Resumen

Para la exportación de aguacate "Hass" se requiere cumplir con altos estándares de calidad, entre los que se destaca la madurez de la fruta. Sin embargo, la fruta cosechada presenta heterogeneidad de maduración y se requiere una solución que permita identificar el momento óptimo de cosecha. El momento óptimo se caracteriza porque la fruta alcanza su madurez fisiológica. Para medir la madurez se usa como referente el contenido de materia seca (M.S.) y los métodos no destructivos para su predicción son muy costosos o no son operativos. Por lo tanto, se presenta una solución que permite identificar si un fruto tiene madurez fisiológica en el árbol. La solución tiene un método y un dispositivo con dos casos de uso: clasificación y parametrización del sistema. La clasificación usa una máquina de soporte vectorial entrenada para clasificar un vector optimizado de descriptores de textura calculado de una imagen de la fruta en el árbol. La imagen es en formato RGB, sin compresión y con resolución espacial homogénea. La imagen tiene un pretratamiento con la ecualización de histograma adaptativo limitada por contraste y la conversión a un espacio de color HSV. De la imagen HSV se usa un segmento para calcular un vector optimizado de descriptores de textura. El caso de uso de parametrización es para optimizar el vector de descriptores de textura. Este vector es el conjunto de descriptores que permiten mayor eficacia de clasificación en validación cruzada y un menor costo computacional. El dispositivo implementa el método y debe realizar la clasificación en tiempo real, con portabilidad y robusto. Los principales aportes del proceso de investigación, desarrollo e innovación son: Al evaluar destructivamente todos los frutos de un árbol en temporada de cosecha se demostró que la fruta presenta heterogeneidad de maduración, con una variación entre frutos superior a 20 % de M.S.. Se demostró que el método en un ambiente relevante tiene una eficiencia de clasificación del 98.2 %, lo cual soporta la solicitud de patente de la solución propuesta. Se proyecta que si un agricultor implementa la invención tendría un aumento de los ingresos en un 91.4 %.

Abstract

For "Hass" avocado exportation is required high quality standards, such as fruit maturity. However, the harvested fruit presents heterogeneity of ripeness, requiring a solution that allows identifying the optimal time of harvest. The optimal time is associated with the physiological maturity. And the dry matter (D.M.) content is used to measure the maturity. But, the nondestructive methods to predict its content are very expensive or are not operative. So, we present a solution to identify if a fruit has physiological maturity on the tree. The solution involves a method and a device with two use cases: classification and system parameterization. The classification use case use a support vector machine trained to classify a vector of texture descriptors calculated from an image of the fruit on the tree. The image is acquired in RGB format, without compression and with homogeneous spatial resolution. The image is pre-treated with a contrast limited adaptive histogram equalization and a conversion to an HSV color space. A segment of the HSV image is used to calculate an optimized vector of texture descriptors. The parameterization use case is to optimize the vector of texture descriptors. This vector is a set of textures descriptors with high efficient cross-validation classification and lower computational cost. The device implements the method and must perform the classification in real time, with portability and ruggedness. The main contributions of the process of research, development and innovation are: This research shows that the fruit has a heterogeneous maturity. For that we test all the fruits of a tree in a harvest season, presenting a variation among fruits upper to 20% of D.M. . we prove the viability of the method in a relevant environment, which a classification efficiency of 98.2% that supports the patent application of the proposed solution. And if a farmer implements the invention, he will have an increase of income in 91.4%.

Agradecimientos

En primer lugar la gobernación del Tolima, por la beca otorgada mediante la convocatoria de Colciencias No 755, con presupuesto de regalías, y al grupo CEDAGRITOL por el aval dado por para participar en esta convocatoria.

En segundo lugar al doctor Sergio Alejandro Orjuela, el doctor Andres Ignacio Hernandez y el doctor Rafael Gutiérrez y el equipo de trabajo del Doctorado de Ciencia Aplicada de la Universidad Antonio Nariño, por la Guía y acompañamiento para la generación de una innovación patentable.

En tercer lugar a la doctora Angelica Piedad Sandoval Aldana, de la Facultad de Ingeniería Agronómica de la Universidad del Tolima, por su colaboración en investigación, que me permitió la adquisición de datos de campo.

En cuarto lugar al doctor Hiep Loung y el doctor Michiel Vlaminck. Adscritos al departamento "Telecommunications and Information Processing (TE-LIN)" de la universidad de Ghent, por el apoyo y guía presentada en la pasantía internacional.

En quinto lugar, agradecerle especialmente a mi esposa y mi madre, quienes siempre han sabido brindarme su apoyo durante todos los años de este doctorado.

Finalmente, a mis compañeros con los cuales tuve disertaciones enriquecedoras que me permitieron llevar este proceso a feliz termino.

Lista de abreviaturas y acrónimos

CHDK: Canon Hack Development Kit.

CLAHE: Ecualización de Histograma Adaptativo Limitada por Contraste.

DNG: del inglés Digital Negative.

GLRLM: Gray Level Run Length Matrix.

H: Matiz (del inglés Hue).

Histo: Histograma.

LBP: Local Binary Pattern.

LUX mod: espacio de color LogarithmicUeeXtension.

M.S.: Materia Seca.

m.s.n.m.: Metros sobre el nivel del mar.

RGB: Rojo, verde y azul (del inglés Red, Green, Blue).

S: Saturación (del inglés Saturation).

Std: Desviación estándar.

V: Valor (del inglés Value).

Tabla de contenido

1. Introducción	1
2. Estado del arte	5
2.1. Métodos actuales para determinar la madurez fisiológica del fruto.	5
2.1.1. La textura de la piel del aguacate Hass cambia a través de su crecimiento.	7
2.1.2. Clasificación de la madurez del fruto en el árbol.	8
2.2. Búsqueda de patentes	9
3. Metodología	12
3.1. Problema de investigación	12
3.2. Descripción detallada de la solución	12
3.2.1. Método para clasificar la madurez del fruto mediante un conjunto de patrones de textura y parametrización del modelo	13
3.2.2. Método para cosechar fruta con madurez homogénea	14
3.3. Dispositivo	15
3.4. Validación del método	17
3.5. Datos de laboratorio	20
4. Resultados y Análisis	22
4.1. Cuantificación del problema de investigación	22
4.1.1. Heterogeneidad de maduración al momento de la cosecha	22
4.1.2. Dificultad de diagnóstico visual de la madurez del fruto recién cosechado	22
4.2. Validación del método	23
4.3. Proyección de los ingresos extra que genera la solución	26
5. Producción	28
5.1. Productos	28
6. Conclusiones	30

Bibliografía	32
Anexos	41
A. Solicitud de patente	42
B. Artículo 1	85
C. Artículo 2	95
D. Artículo 3	108
E. Artículo 4	124
F. Ponencia en congreso internacional	137
G. Lienso CANVAS del modelo de negocio	141

Lista de tablas

1.1. Requerimientos técnicos	2
2.1. Brecha tecnológica con patentes similares y con otros usos. . .	10
3.1. Descriptores de textura usados en la validación del método . .	20
4.1. Precisión de la clasificación de frutos de aguacate "Hass", con maquina de soporte vectorial, en relación al origen de los da- tos para la optimización del vector de descriptores de textura. .	24
4.2. Precisión de la clasificación de frutos de aguacate "Hass", usando maquina de soporte vectorial con diferentes configu- raciones del kernel de la maquina de soporte vectorial para la optimización del vector de descriptores de textura, usando la fuente de datos con corrección de histograma y los canales H, S y V.	25
4.3. Proyección del tiempo operacional extra en la implementa- ción de la solución en un árbol	27
4.4. Proyección de los ingresos con el método actual y la solución planteada por árbol, para un agricultor exportador de aguacate "Hass".	27
5.1. Productos	29

Lista de figuras

1.1.	Diseño conceptual del sistema	4
3.1.	Proceso para determinar el conjunto optimizado de descriptores de textura.	14
3.2.	Monitoreo regional de madurez de aguacate.	15
3.3.	Diseño conceptual del dispositivo	15
3.4.	Casos de uso del prototipo	16
3.5.	Caso de uso clasificación	17
3.6.	Caso de uso de parametrización del modelo	17
3.7.	Adquisición de imágenes en el árbol.	18
4.1.	Histograma del número de frutos en relación con el contenido de materia seca para un árbol de aguacate "Hass", recién cosechado, en el semestre b de 2018, municipio de Fresno, Tolima.	22
4.2.	Eficacia de clasificación de aguacate "Hass" en el árbol, mediante el uso de una maquina de soporte vectorial entrenada con un vector de descriptores de textura optimizado a partir de un segmento de una imagen del fruto, con corrección de histograma y el uso de los canales H, S y V de la imagen. . . .	25
4.3.	Histograma del número de frutos de un árbol de aguacate "Hass" en relación con el contenido de materia seca, agrupados en rangos de 6,5 % de contenido de materia seca. . . .	26

Capítulo 1: Introducción

Colombia como quinto productor de aguacate (Faostat, 2020), busca posicionarse en el mercado internacional (Ministerio de Agricultura y Desarrollo Rural, 2016), la variedad "Hass" es la de mayor comercialización y ésta requiere ser cosechada con madurez fisiológica (ICONTEC, 2003). La fruta para exportación debe estar en el rango de 23,5 % (C. Carvalho, Velásquez, y Van Rooyen, 2014) (madurez fisiológica) y 30 % de materia seca (Astudillo-Ordóñez y Rodríguez, 2018).

La clasificación visual de la madurez de la fruta no es efectiva (Cerdas Araya, Montero Calderón, y Somarribas Jones, 2014) por tanto el agricultor realiza cosecha generalizada. Para la definición del momento de cosecha el agricultor aplica métodos estadísticos para estimar el contenido de materia seca promedio del huerto, con el uso de métodos destructivos o no destructivos (Magwaza y Tesfay, 2015). Sin embargo, debido a la heterogeneidad del desarrollo de la fruta en el árbol (Hofman y Jobin-Decor, 1999; Estrada y Alonso, 2016), en Colombia aproximadamente el 50 % de la fruta no cumple los parámetros de madurez para exportación, causando pérdidas para el agricultor.

Los métodos reportados para la clasificación de la madurez del aguacate se usan en postcosecha o requieren contacto con la fruta (espectrómetro) o son experimentales y muy costosos (cámaras hyperespectrales). Por lo tanto, el problema es que: **los métodos actuales para determinar el tiempo óptimo de cosecha del aguacate Hass en el árbol fallan en su operatividad o confiabilidad** y el agricultor requiere una solución con los requerimientos técnicos presentados en la tabla 1.1.

Tabla 1.1: Requerimientos técnicos

Criterio	Condición	Valor objetivo
Clasificar la madurez fisiológica	Clasificar la fruta en dos grupos usando como umbral el índice de cosecha	23,5% *
	Frutas en el árbol	Antes de cosecha
	Uso por parte del trabajador agrícola	8 a 10 horas/día
	Sin contacto con la fruta	0,3 a 3 m de distancia
	Tiempo de respuesta	5 s
	Resistente al clima del cultivo	
	Altitud	1400 - 2400 m.s.n.m. *
	Temperatura	18 - 20 °C *
	Humedad relativa	60 -75 % *
Homogeneizar la madurez de la fruta cosechada	Solo cosechar fruta con un rango de madurez para exportación	23.5% a 30% de M.S. * (delta de 6.5% de M.S.)

* Parámetros válidos para Colombia (C. Carvalho y cols., 2014).

El mejor enfoque para determinar la madurez fisiológica del aguacate Hass para la exportación, implica el uso de técnicas no destructivas directamente en el árbol. El uso de imágenes es un método potencialmente superior para determinar el momento óptimo de cosecha, ya que es rápido y menos costoso. Se ha investigado el uso de imágenes para inferir el contenido de materia seca de la fruta de aguacate (Magwaza y Tesfay, 2015), sin embargo, las investigaciones se han realizado en postcosecha. Una revisión reciente de Li, Lecourt & Bishop (2018) encontró que existen estudios en manzanas, bananos, tomates y piñas para determinar el momento óptimo de cosecha mediante la técnica de procesamiento de imágenes visuales, enfatizado en medidas del color. Sin embargo, el color no sirve como parámetro de clasificación de la madurez del aguacate (Osuna-García, Doyon, Salazar-García, Goenaga, y González-Durán, 2011). Otros estudios demuestran cambios en el color y la rugosidad de la piel del aguacate en el árbol (Medina-Carrillo y cols., 2017), y el parámetro visual usado para determinar la madurez de este en el árbol es el cambio de brillo (Bernal, Díaz, Osorio, Tamayo, y Osorio, 2014). Por lo tanto, se requiere una técnica invariable a la rotación e iluminación que evalúa la variación en la textura y el brillo del aguacate.

La solución propuesta es: **determinar el momento óptimo de cosecha del aguacate "Hass" para exportación, clasificando si el fruto tiene madurez fisiológica en el árbol mediante procesamiento de imágenes.**

La madurez fisiológica se clasifica en función al contenido de materia seca de la fruta. Para clasificar se usa un algoritmo de clasificación entrenado. El procesamiento de la imagen determina un conjunto optimizado de descriptores de textura de una imagen en escala de grises de la fruta con resolución espacial homogénea, se puede usar de uno a los tres canales de la imagen convertida a espacio de color HSV. Para solo cosechar fruta en un rango de maduración de exportación se plantea repetir este proceso de clasificación y recolección cada dos meses. Es de resaltar que en la investigación realizada no se han encontrado patentes y publicaciones que implementen el uso de un conjunto de descriptores de textura de imágenes visuales para clasificar la madurez fisiológica del aguacate en el árbol.

La solución propuesta tiene como limitación la variabilidad de las características visuales de la fruta según las condiciones ambientales. Por ejemplo en una investigación con imágenes hiperespectrales el contenido de materia seca perdió la correlación con los resultados cuando los datos de dos ubicaciones se unificaron (Pineda Tobón, 2017); y en mediciones con espectroradiómetro se determinó que la reflectancia espectral del aguacate "Hass" está influenciada por la región geográfica (Wedding y cols., 2011) y la temporada entre años (Wedding y cols., 2013), por lo que los investigadores sugieren realizar modelos independientes para cada región. Por lo tanto, se incluye un método de parametrización del modelo de clasificación para cuando se cambia de región.

Para cumplir los requerimientos de diseño se requiere un dispositivo que implemente el método y adquiera imágenes de la fruta con una resolución espacial homogénea. Por tanto, se ha diseñado un método y un dispositivo que configuran el sistema propuesto (Figura 1.1), el método asociado al dispositivo tiene dos módulos uno de clasificación y otro de parametrización.

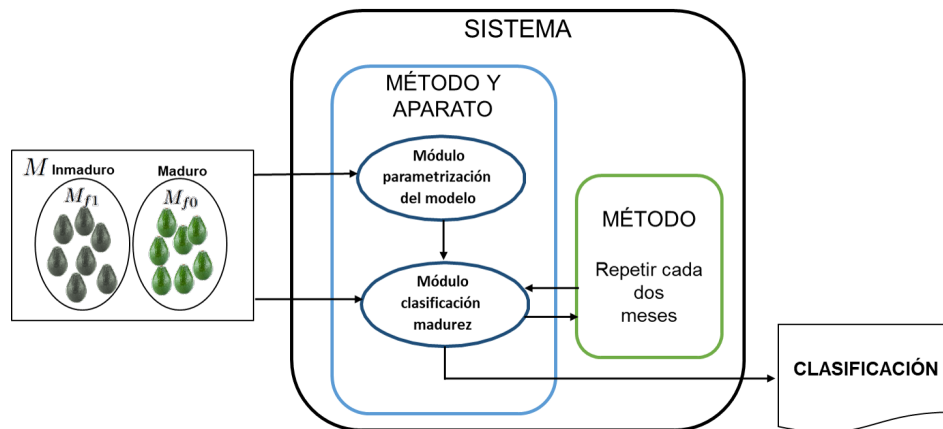


Figura 1.1: Diseño conceptual del sistema

La solución propuesta presenta novedad, actividad inventiva y aplicación industrial, lo que permitió sustentar la presentación de una solicitud de patente (Anexo A). De tal forma que, en este documento de investigación, desarrollo e innovación se presenta: los fundamentos teóricos de la solución propuesta, las mediciones realizadas para sustentar el problema, la demostración del método, la proyección económica de la solución y la producción intelectual asociada al proceso de formación doctoral.

Capítulo 2: Estado del arte

Definiciones

Madurez Fisiológica: Etapa de desarrollo cuando una fruta de aguacate continuará la ontogenia incluso después de que se haya desprendido del árbol (Kader, 1999; S. K. Lee y Young, 1983).

Materia Seca: Es la parte que resta de un fruta tras extraer toda el agua posible. El peso obtenido después de la desecación, y calculado su porcentaje, representa el extracto seco (C. Carvalho y cols., 2014).

Índice de cosecha aguacate: Contenido de materia seca de la fruta en el cual alcanza su madurez fisiológica

Descriptor de textura: Representa las características de una textura en una imagen (Simon y Uma, 2018).

Resolución espacial de una imagen: Es una indicación del tamaño del píxel expresada en términos de dimensiones sobre el terreno.

2.1. Métodos actuales para determinar la madurez fisiológica del fruto.

Una gran dificultad que tienen los productores de aguacate en el momento de la cosecha es conocer el momento óptimo para recoger la fruta. Determinar este momento es muy complejo, ya que la fruta no madura mientras esta se encuentra en el árbol (C. P. Carvalho y Velásquez, 2015). Actualmente, los agricultores usan el método visual que no es efectivo (Bernal y cols., 2014; Cerdas Araya y cols., 2014). Sin embargo, la literatura reporta otros métodos (Magwaza y Tesfay, 2015).

El indicador más importante del índice de cosecha es el contenido de aceite de la fruta. Por tanto, el momento óptimo de cosecha es cuando la fruta contiene un nivel adecuado de aceite (C. Carvalho y cols., 2014). Sin embargo, determinar el contenido de aceite es un método costoso y el contenido de materia seca tiene un modelo de correlación lineal con el contenido de aceite, por lo que se usa como referente el contenido de materia seca. En Colombia, el índice de cosecha es con un contenido de aceite superior al 11,2%, y de materia seca de la fruta de 23,5% (C. Carvalho y cols., 2014).

El índice de cosecha puede determinarse mediante métodos destructivos y no destructivos. Actualmente los métodos destructivos son más precisos, pe-

ro necesitan el laboratorio. Para determinar el contenido de aceite se utiliza la extracción con solvente y para determinar el contenido de materia seca es necesario desecar la fruta (Magwaza y Tesfay, 2015). Sin embargo, los agricultores necesitan métodos que sean más baratos y más prácticos. Entre los métodos destructivos esta el uso de hornos de microondas para determinar la materia seca de los frutos en las granjas (Marcante y cols., 2010) y realizar proyecciones estadísticas.

También es posible utilizar técnicas no destructivas. Magwaza (2015) documentó varios métodos: en primer lugar, hay métodos basados en información visual e infrarroja (longitudes de onda visuales e infrarrojas) que incluyen espectrofotometría, imágenes hiperespectrales y procesamiento de imágenes visuales. En segundo lugar, los basados en ultrasonido. Y finalmente, aquellos basados en imágenes de resonancia magnética nuclear. Pero todos estos métodos requieren condiciones controladas y se utilizan principalmente en la clasificación poscosecha.

Si bien los métodos destructivos para frutas individuales son más precisos que los no destructivos, no son confiables para la cosecha generalizada debido a la heterogeneidad de la maduración de la fruta. Por ejemplo, en Colombia, hay un rango de hasta cuatro meses en la floración del árbol (Estrada y Alonso, 2016). Como resultado, si un agricultor usa la técnica del horno de microondas sin tener en cuenta la heterogeneidad de la floración del árbol tendría heterogeneidad de madurez en la fruta cosechada.

Los métodos no destructivos son más fáciles de usar para los agricultores, y los más fáciles son los métodos visuales como el espectrómetro. Sin embargo, el uso de un espectrómetro necesita condiciones controladas y contacto con la fruta (Blakey, 2016; Olarewaju, Bertling, y Magwaza, 2016), y esto limita su uso por parte del recolector. Otros métodos, como las cámaras hiperespectrales son caros y requieren un procesamiento especializado (Denis Girod, Landry, Doyon, y Osuna Garcia, 2008; Vega Diaz, Sandoval Aldana, y Reina Zuluaga, 2020). Por esta razón, el método que usa imágenes RGB tienen ventaja porque no necesitan contacto con la fruta y requieren un costo computacional menor (B. Li, Lecourt, y Bishop, 2018).

2.1.1. La textura de la piel del aguacate Hass cambia a través de su crecimiento.

Varios cambios ocurren en la apariencia externa de la fruta de aguacate a medida que crece, y estos cambios son útiles para los métodos de imagen visual. Por esta razón, necesitamos métodos para caracterizar el desarrollo del fruto. Desafortunadamente, los métodos actuales utilizados para caracterizar el desarrollo del fruto no están estandarizados.

Algunas investigaciones emplearon diferentes métodos para medir el desarrollo del fruto, tales como el seguimiento con la escala BBCH ("Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie") (Alcaraz, Thorp, y Hormaza, 2013), la medición del diámetro (Medina-Carrillo y cols., 2017) o el registro de semanas después de la plena floración (Cowan, Taylor, y van Staden, 2005). Con las mediciones reportadas se evidencia que hay dos fases: una fase de crecimiento inicial y una fase de crecimiento lineal (Dixon, Lamond, Smith, y Elmsly, 2006).

El contenido de materia seca del fruto en la fase de crecimiento lineal, tanto cuatro meses antes en la madurez fisiológica como dos meses después, tiene un comportamiento similar a un modelo lineal (New Zealand Avocados, 2018). En esta fase, la piel de la fruta exhibe cambios bioquímicos en la concentración de clorofilas, carotenoides, compuestos fenólicos y lignina. Las concentraciones de antocianinas también muestran un aumento sostenido en función del tiempo; así mismo, la lignina y las clorofilas aumentan en menor grado. En contraste, la concentración de fenoles disminuye con el tiempo (Medina-Carrillo y cols., 2017).

Estos cambios bioquímicos a su vez, conducen a cambios en la apariencia de las frutas. Por ejemplo, el cambio en la concentración de clorofila, como la antocianina, implica una variación en el color del tono rojo (Richardson, Duigan, y Berlyn, 2002), y los cambios en la lignina y los compuestos fenólicos implican cambios en la aspereza y el brillo de la fruta. Las variaciones en estos compuestos se reflejan en los cambios de color de la piel.

Sin embargo, existe una variabilidad en el comportamiento del color de la fruta en diferentes ambientes. Por ejemplo: la calidad de la fruta no se

correlaciona bien con el color de la piel (Osuna-García y cols., 2011). El origen y la madurez de la fruta pueden influir en los cambios de la cáscara del aguacate, debido a las diferencias en los niveles de antocianinas (Donetti y Terry, 2012; Pineda Tobón, 2017). Y la rugosidad de la piel del fruto está relacionada con la temperatura ambiental en la que se desarrolla el cultivo (Alvarez bravo y Salazar-Garcia, 2017). Toda esta variabilidad dificulta la clasificación visual de la madurez del fruto para la cosecha.

2.1.2. Clasificación de la madurez del fruto en el árbol.

La clasificación de los frutos en el árbol presenta algunas dificultades. En primer lugar, necesitamos una técnica no destructiva de medición de materia seca. En segundo lugar, la técnica debe ser operativa en condiciones ambientales. Y finalmente, debe ser fácil de usar para los recolectores. Las técnicas informadas hasta ahora no cumplen con estas condiciones, pero la clasificación por patrones de textura de imagen visual tiene el potencial de cumplirlas.

La clasificación del patrón de textura de la imagen es un área del procesamiento de imágenes que extrae algunas características del objeto para su clasificación (Duda, Hart, y Stork, 2001). Los descriptores de textura caracterizan una imagen con diferentes métodos: estadísticos, procesamiento de señal o modelado de imagen. Esto hace posible generar una caracterización de textura invariable a la rotación e iluminación (L. Liu, Zhao, Guo, Wang, y Tang, 2018).

El análisis de texturas por algoritmo estadístico analiza las relaciones y la distribución de píxeles y evita las relaciones jerárquicas (Fernández Lozano, 2014). Los algoritmos más reconocidos de este grupo son: sum and difference histograms, co-ocurrence matrix, gray level run length matrix (GLRLM), local binary pattern (LBP) (Orjuela Vargas, 2013). En general, las técnicas que usan estadísticas generan descriptores de textura con datos puntuales. Sin embargo, el LBP genera una matriz de valores que representan el contraste entre píxeles. La imagen LBP se convierte en un histograma y se caracteriza con variables estadísticas.

Otro grupo de algoritmos son los métodos de procesamiento de señales, que transforman el sistema de coordenadas de la imagen para encontrar la re-

presentación de la textura. Los algoritmos más reconocidos de este grupo son: Lawl's texture measures, Eigenfilter, Gabor filter, the gaussian pyramid, the steerable pyramid, Wavelet decomposition, the power spectrum technique y the Wigner distribution (Orjuela Vargas, 2013). Los algoritmos que procesan las señales generan series de datos, que pueden caracterizarse con variables estadísticas que se utilizarán como descriptores de textura.

Finalmente están los algoritmos de textura basados en modelos, que obtienen buenos resultados con texturas naturales (Fernández Lozano, 2014). Los algoritmos más reconocidos de este grupo son autoregressive models y gaussian Markov random field (Orjuela Vargas, 2013). En la investigación realizada no se han encontrado reportes del uso de descriptores de textura para determinar la madures fisiológica del fruto de aguacate en el árbol, o con frutas recién cosechadas.

2.2. Búsqueda de patentes

Para fundamentar el proceso de investigación, desarrollo e innovación se analizó las capacidades, métodos y funcionalidad de la propuesta frente a patentes con otros usos. Los resultados se presentan en la tabla 2.1. En esta tabla se pude observar la columna brecha, la cual nos presenta la diferencia con el método propuesto y porque no puede aplicarse al problema planteado.

Tabla 2.1: Brecha tecnológica con patentes similares y con otros usos.

Patente	Capacidades	Métodos	Funcionalidad	Brecha
Method for selecting proper time for harvesting avocado JP2002330625	Seleccionar el momento de cosecha cuando la proporción de la de la epidermis total del aguacate color negro es del 5 al 80%	<ul style="list-style-type: none"> * Calientan y maduran el aguacate transportado en una planta procesadora. * Clasificación visual 	Fruto Inducido Para Madurar.	<ul style="list-style-type: none"> * Proceso post cosecha * Clasificación visual
Harvesting method for persea americana JP2016036286	<ul style="list-style-type: none"> * La cosecha del aguacate se realizará de manera eficiente. * Los aguacates recolectados son aproximadamente de la misma calidad (madurez) que los aguacates recolectados por los expertos 	Marca de identificación en el tallo por floración, cuatro marcas por año.	Agrupar los frutos de la misma floración.	<ul style="list-style-type: none"> * Similar a la clasificación visual * Recolección simultánea de frutas en grupo. * Colombia tiene un largo periodo de floración.
Method for determining maturation of tobacco leaves and method for harvesting tobacco leaves CN103823050	Un método para juzgar la madurez de las hojas de tabaco.	Juzgan una expresión de al menos uno, dos, tres o cuatro características como: color de la hoja, vena, superficie de la hoja y ángulo de la hoja de tabaco.	Tiempo óptimo de cosecha.	<ul style="list-style-type: none"> * Es una clasificación visual
Fruit maturity degree evaluation method based on spectrum and color measurement CN102818777	Un método para evaluar la madurez de la fruta.	Combinan espectroscopia visible de infrarrojo cercano y un modelo de calidad integrado a través del aprendizaje automático.	Evaluación de fruta	<ul style="list-style-type: none"> * Espectómetro (380 a 1700 nm) * Iluminación halógena * Medición multipunto del ecuador de la fruta, en contacto directo. * No es operativo para un proceso de recolección

Tabla 2.1 continua de la página anterior

Patente	Capacidades	Métodos	Funcionalidad	Brecha
Fruit maturity evaluation method based on maturation rule CN104597217	Modelo de fruta madura	El color de la cáscara, el contenido de clorofila de la cáscara, el contenido de sólidos solubles en la fruta y el contenido de vitamina C se estudian en función de la temperatura acumulada efectiva de la fruta madura.	Cuantifica la madurez de la fruta.	<ul style="list-style-type: none"> * No especifica patrones de textura de la piel * En el aguacate no se puede clasificar su madurez fisiológica con el color.
Portable device for selective harvest with identification of the fruit by colour WO2015121809	<ul style="list-style-type: none"> * Equipo portátil para la cosecha selectiva de frutas en una rama. * Método para la identificación de frutos por color y cosecha selectiva. 	Adquiere imágenes, preprocesa imágenes, convierte de espacio de color RGB a LUX mod; umbraliza y detecta los píxeles de frutas maduras e inmaduras; cuenta los píxeles; detecta áreas de interés; calcula el umbral de riesgo; y finalmente enviar señal de cosecha.	Determinar si una fruta de café está madura para cosechar.	<ul style="list-style-type: none"> * No especifica patrones de textura de la piel de la fruta * En el aguacate no se puede clasificar su madurez fisiológica con el color.
Fruit grading system based on neural network-Fruit level classification system based on external quality CN102855640 - CN102855641	Sistema de clasificación de frutas basado en fusión clasificador múltiple.	<ul style="list-style-type: none"> * Información de la fruta: forma, transformación de los datos RGB y un área * Red neuronal 	Clasificación de frutas	<ul style="list-style-type: none"> * No especifica patrones de textura de la piel de la fruta * No clasifica la madurez fisiológica del aguacate. * No está probado para fruta en el árbol
Image content classification methods, systems and computer programs using texture patterns US5995651	Un método de clasificación de contenido de imagen.	Extrae la pluralidad de patrones de textura y clasifica en una red neuronal	Clasificación de imágenes	<ul style="list-style-type: none"> * Este no especifica la conversión de RGB a HSV * No especifica un modelo correlacional con la madurez de la fruta en entornos no controlados.

Capítulo 3: Metodología

Este aparte se basa en un proceso de investigación, desarrollo e innovación que permite la generación de soluciones novedosas a problemas de un sector industrial. El trabajo presentado incorpora intrínsecamente metodologías como la teoría para resolver problemas de inventiva (TRIZ) y la evaluación del nivel de madurez tecnológica (TRL) entre otros.

3.1. Problema de investigación

El problema en la cosecha es que: El aguacate "Hass" cosechado para exportación presenta heterogeneidad en el estado de maduración, debido a causas fisiológicas, morfológicas y de dificultad de diagnóstico en el árbol. Este problema conlleva a pérdidas postcosecha en la finca como en la cadena de exportación.

En investigaciones similares, Hofman (1999) relacionó la variabilidad de la fruta entre árboles, determinando el contenido de materia seca de 12 frutos por árbol. El contenido de materia seca presentó un rango entre 14,6 y 23,5 % M.S.. Planteando en una de sus conclusiones que la variabilidad en el porcentaje de materia seca y días desde la cosecha hasta la maduración entre frutos y entre árboles indica una inconsistencia indeseable en la calidad del fruto a nivel del consumidor.

Para determinar la variabilidad en la maduración del fruto se recolectaron todos los frutos presentes en un árbol en la temporada de cosecha. Los frutos analizados fueron recolectados el 20 de diciembre de 2018. La ubicación del cultivo es en el municipio de Fresno, finca Alto bonito, en las coordenadas 5°08'21.6"N, 75°06'22.5"W, a 1900 metros sobre el nivel del mar, y con una temperatura ambiental promedio de 20 °C. Se recolectaron todos los frutos que presentaran un tamaño óptimo para análisis (botones o frutos en estado de desarrollo no se tuvieron en cuenta). Los frutos fueron transportados y adecuados el mismo día de la cosecha para los análisis de laboratorio.

3.2. Descripción detallada de la solución

Este aparte del documento es complementario con la solicitud de patente presentada en el anexo A. y el efectividad del método, que es demostrado en

el artículo del anexo D.

3.2.1. Método para clasificar la madurez del fruto mediante un conjunto de patrones de textura y parametrización del modelo

El módulo de clasificación de la madurez usa una imagen de la piel del aguacate en formato RGB, sin compresión y con resolución espacial homogénea. A esta imagen se le realiza el siguiente pre-tratamiento: se calcula una ecualización de histograma adaptativo limitada por contraste (CLAHE) y se transforma a un espacio de color HSV. De la imagen HSV se extrae un segmento y por cada canal de la imagen se determina un conjunto optimizado de descriptores de textura. Finalmente, se realiza la clasificación binaria utilizando un algoritmo de clasificación entrenado para tal fin.

El módulo de parametrización del modelo implica el proceso de selección del conjunto optimizado de descriptores de textura y el entrenamiento del algoritmo de clasificación. Este módulo se usa cuando la clasificación pierde precisión o se implementa la solución en zonas climáticas diferentes.

Para la selección del conjunto optimizado de descriptores de textura se usan tres pasos: primero, se adquieren segmentos clasificados de imágenes que han tenido el mismo procesamiento que en el módulo de clasificación, esta base de datos se divide en dos, una para entrenamiento y otra para test. Para determinar la clasificación de los segmentos se determina la madurez del fruto, ya sea determinando el contenido de materia seca o realizando una clasificación visual de frutas muy inmaduras o muy sobre maduras. Segundo, se calcula el mayor número de descriptores posibles de los segmentos clasificados. Tercero, se selecciona los descriptores de textura que cumplan las siguientes condiciones: permitan separabilidad de los grupos de imágenes con un valor de probabilidad del test de anova inferior a 0.01; presenten una correlación inferior a 0,5; presenten bajo costo computacional; usando el clasificador seleccionado presenten una eficacia de predicción en validación cruzada con la base de datos de entrenamiento superior al 95 % y con la base de datos de test una eficacia de predicción superior al 95 %. Este proceso se esquematiza en la figura 3.1.

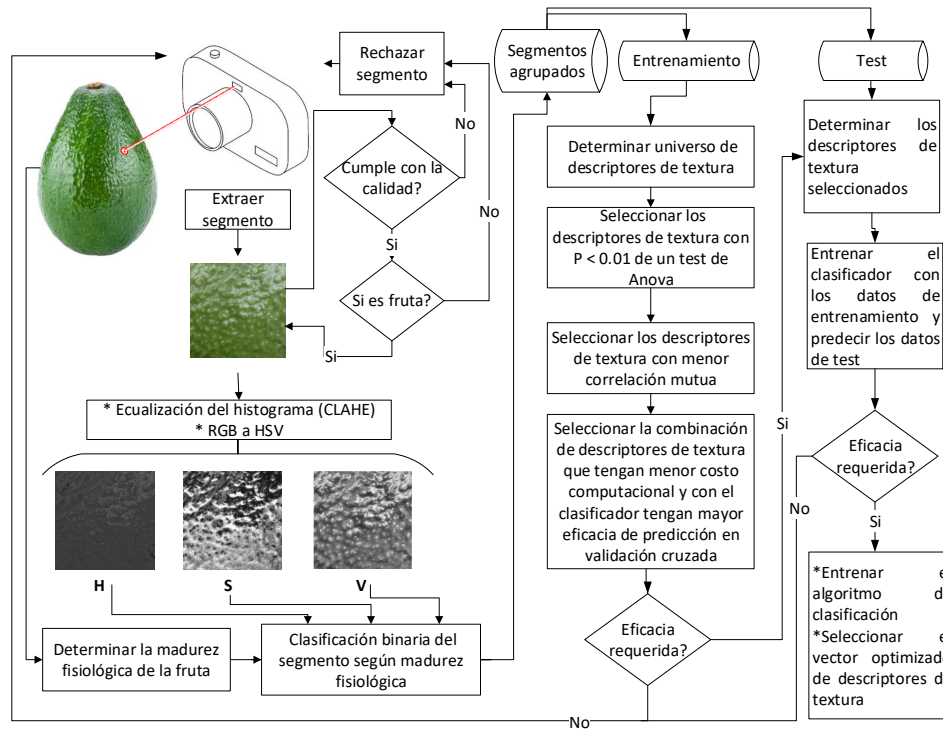


Figura 3.1: Proceso para determinar el conjunto optimizado de descriptores de textura.

El clasificador se entrena con los valores del vector optimizado de descriptores de textura que representan los segmentos de imagen clasificados.

3.2.2. Método para cosechar fruta con madurez homogénea

Para cumplir con el requerimiento de cosechar la fruta con el rango de madurez para exportación se propone repetir el método periódicamente. El rango de madurez de exportación en Colombia es de 6.5% de materia seca. Para determinar el periodo de repetición se analiza la acumulación de materia seca en el árbol, representado en la figura 3.2.:

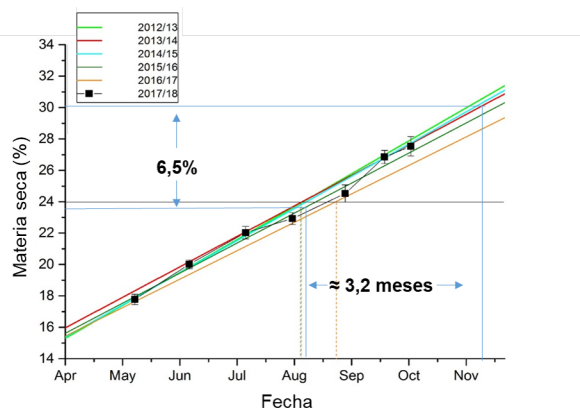


Figura 3.2: Monitoreo regional de madurez de aguacate . (New Zealand Avocados, 2018).

Como se observa en la gráfica 3.2 el delta de 6,5% de materia seca es equivalente a 3,2 meses de la fruta en el árbol. Sin embargo, según estudios ecofisiológicos el mayor periodo de floración en Colombia es de cuatro meses (Estrada y Alonso, 2016), por lo tanto, se propone calcular este periodo en la zona productora.

3.3. Dispositivo

El dispositivo implementa el método propuesto en la sección anterior para clasificar la madurez fisiológica del fruto. Partiendo del método propuesto el dispositivo requiere: imagenes en un formato sin compresión, segmento de la imagen de una fruta con una resolución de 1 a 3 Megapixeles, foto directa a la fruta, fotos con resolución espacial homogénea, el usuario señala la fruta, la foto sin obstáculos (lluvia, ramas, hojas...), sin movimiento de la fruta o el operario por 1/120 segundos, se proyecta procesar una fruta a la vez, y el dispositivo debe tener una interfaz intuitiva para un trabajador agrícola sin limitacion visual o auditiva (Figura 3.3).




Figura 3.3: Diseño conceptual del dispositivo

El elemento diferenciador de este dispositivo es la disposición de los componentes para suplir los siguientes parámetros:

- Foto con resolución espacial homogénea: el concepto es medir la distancia del usuario con el objeto y aplicar una de dos opciones: que el equipo realice zoom automático a la fruta o que el usuario se desplace hasta una distancia predeterminada, para que automáticamente el dispositivo tome la foto.
- Clasificación con capacidad de respuesta inferior a 5 segundos: el dispositivo y los algoritmos deben ser optimizados para que la clasificación de la fruta sea en tiempo real.
- Usabilidad para un trabajador en un entorno operacional agrícola: se requiere un diseño intuitivo, liviano y robusto.

Se ha diseñado un dispositivo con cinco componentes: subsistema de adquisición, subsistema de procesamiento y almacenamiento (interno y de procesamiento web), interfaces de usuario, subsistema de comunicación y fuente de energía, con los cuales se implementan dos casos de uso (Figura 3.4): clasificación (figura3.5) y parametrización del modelo (Figura 3.6).

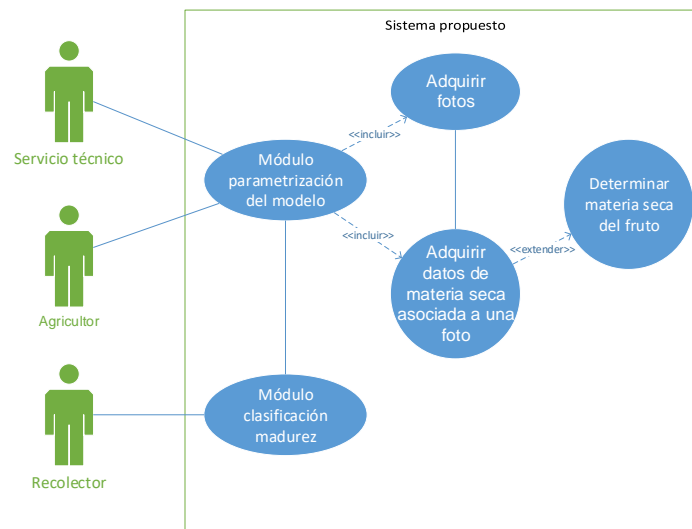


Figura 3.4: Casos de uso del prototipo

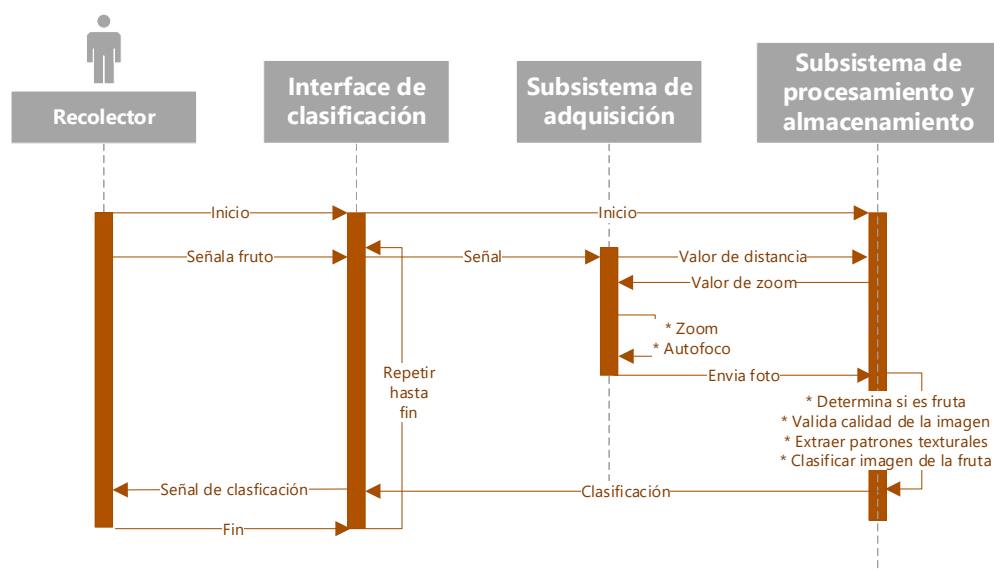


Figura 3.5: Caso de uso clasificación

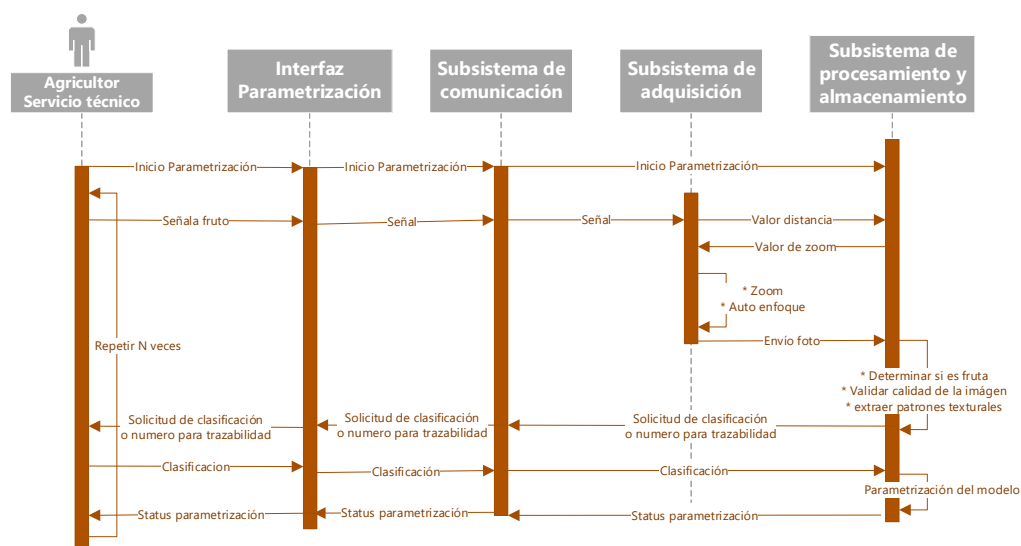


Figura 3.6: Caso de uso de parametrización del modelo

3.4. Validación del método

La innovación tecnológica se fundamenta en un método para clasificar la madurez fisiológica de los frutos de aguacate en el árbol procesando un segmento de imagen RGB convertida a HSV, sin compresión y con una resolución espacial homogénea. De la imagen HSV se calcula un conjunto de descriptores de textura y se clasifican con un clasificador binario entrenado.

Para demostrar que el método funciona en un contexto relevante, se tomaron fotos de aguacates "Hass" directamente en el árbol y se determinó con métodos destructivos su contenido de materia seca. Las fotos fueron asociadas al estado de madurez y se optimizaron diferentes vectores de descriptores de textura para evaluar la eficiencia de clasificación.

Las fotos se adquirieron con una cámara Canon A2600. Para lograr el parámetro de una imagen sin compresión, se modificó la cámara con el software CHDK y así obtener imágenes en formato DNG. En busca de cumplir el parámetro de imágenes con resolución espacial homogénea, se elaboró un montaje para la adquisición de las fotos (figura 3.7). Finalmente se adquirieron de 3 a 4 fotos por fruto desde diferentes ángulos.




Figura 3.7: Montaje para la adquisición de imágenes en el árbol. a) Montaje de la cámara para asegurar resolución espacial homogénea b) ubicación del fruto en el árbol,

Se convirtieron las imágenes de formato DNG a formato Raw con el software RawDrop. Posteriormente se segmentó la fruta mediante una función de corte de la imagen con selección manual.

Para determinar si el tratamiento con CLAHE en combinación con cada uno de los canales HSV son estadísticamente significativos en la eficiencia de clasificación, se optimizó un vector de descriptores de textura para cada una de las combinaciones de la fuente de datos. Las combinaciones únicas de las fuentes de datos son 14 .

El clasificación se realiza con una máquina de soporte vectorial entrenada con el vector de descriptores de textura. La evaluación de la eficiencia de clasificación se realiza mediante validación cruzada de 10 grupos. Para la va-

validación cruzada se divide los datos en 10 grupos y para cada grupo se usa un 90% para entrenamiento y un 10% para test, y los datos de test son diferentes para todos los grupos. La eficacia de clasificación toma todas las predicciones en test y las compara con los datos conocidos. Entre los resultados está la precisión de la predicción o la probabilidad de que el vector pertenezca a una clase (inmaduro o maduro).

Como procedimiento general, según el origen de los datos, opcionalmente se calculó la ecualización de histograma adaptativo limitado de contraste (CLAHE) a la imagen recortada. Luego de esta se extrajo un segmento central de $900 * 900$ píxeles, el cual se convirtió a espacio de color HSV y se calcularon para cada canal los descriptores de textura de la tabla 3.1. Obteniéndose 100 descriptores de textura por cada canal. Según la combinación de canales escogida se realizó la optimización del vector de descriptores de textura.

Para la optimización del vector se siguieron tres pasos: primero, se clasificó el conjunto de descriptores en una de dos clases según la madurez del fruto que fue fotografiado (0: inmaduro, 1: maduro). Segundo, se evaluó la probabilidad de cada descriptor para clasificar los frutos entre maduros o inmaduros, con una test de anova, seleccionando los descriptores con una probabilidad inferior a 0.01. Tercero, se realizó un proceso de optimización del vector de descriptores de textura seleccionados basado en el valor de la eficacia de clasificación al eliminar uno a uno los descriptores de textura.

El vector optimizado de cada fuente de datos se usó para realizar 100 repeticiones de la predicción en validación cruzada y se usó el promedio de la eficiencia de clasificación para implementar una test de anova de cuatro grupos. Seleccionando la fuente de datos con mayor eficacia de clasificación.

Tabla 3.1: Descriptores de textura usados en la validación del método

Algoritmo	Descriptores de textura
Sum and Difference Histograms	Energía, entropía, contraste, homogeneidad y correlación
Co-occurrence matrix	Energía, entropía, contraste, homogeneidad y correlación
Gray Level Run Length Matrix (GLRLM)	Short Run Emphasis (SRE), Long Run Emphasis (LRE), Gray-Level Nonuniformity (GLN), Run Length Nonuniformity (RLN), Run Percentage (RP), Low Gray-Level Run Emphasis (LGRE), High Gray-Level Run Emphasis (HGRE), Short Run Low Gray-Level Emphasis (SRLGE), Short Run High Gray-Level Emphasis (SRHGE), Long Run Low Gray-Level Emphasis (LRLGE) and Long Run High Gray-Level Emphasis (LRHGE)
Local binary pattern (LBP)	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
Law's texture measures	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
Eigenfilter	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
Gabor filter	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
The gaussian pyramid	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
The steerable pyramid	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
Wavelet decomposition	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
The power spectrum technique	Media, mediana, desviación estándar, skewness, kurtosis, entropía y diez coeficientes
The Wigner distribution	Media, mediana, desviación estándar, skewness, kurtosis y entropía.
Autoregressive models	Ocho coeficientes
Gaussian Markov random field	Siete coeficientes

3.5. Datos de laboratorio

Transporte: Una vez cosechados los frutos fueron transportados en neveras de poliestireno a 10°C hasta el laboratorio de Postcosecha y Calidad de la Universidad del Tolima (Ibagué, Colombia).

Peso: Este valor se obtuvo mediante el peso del fruto a través de una balanza digital (EW-N, KERN & SOHN GmbH, Balingen, Alemania).

Color: Los parámetros de color fueron medidos usando un colorímetro (CM-5, Konica Minolta, Japón). Los resultados fueron expresados en la escala CieLab (L*: luminosidad o brillo, a*: verdosidad o enrojecimiento y b*: amarillez o azul). Las mediciones fueron realizadas en tres puntos aleatorios en la zona ecuatorial del fruto.

Manejo de las muestras de material vegetal: Para extraer la muestra para el análisis de materia seca, los frutos fueron desinfectados con una solución al 2 g/L de Timsen durante 10 min. Posteriormente se secaron y se extrajo el mesocarpio, el cual fue cortado en trozos de aproximadamente 5 mm y al-

macenado en papel de aluminio. Las muestras fueron almacenadas en bolsas Ziploc® a -80°C en un ultra congelador Kaltis 390 hasta su análisis. Cuando se realizó montaje de muestras se retiró el papel aluminio, se colocó sobre soportes contramarcados y se pesó 0.5g de muestra aproximadamente. Se manejaron dos a cuatro replicas por cada muestra.

Contenido de materia seca: El porcentaje de humedad fue determinado siguiendo el método 925.45 descrito en la AOAC (1995) Se tomó 0.5 g de muestra, los cuales fueron pesados en cápsulas previamente taradas y pesadas. Se usaron cuatro muestras por fruto, que fueron secadas a 105°C durante 24 h, para posteriormente pesarse (Astudillo-Ordóñez y Rodríguez, 2018). Los cálculos se realizaron empleando la siguiente ecuación: (Ecuación 3.1)

$$M.S. = \left(\frac{M_0 - M_1}{M_0} \right) 100 \quad (3.1)$$

Donde: $M.S.$: Porcentaje de contenido de materia seca. M_1 : peso final de muestra. M_0 : peso inicial de la muestra.

Capítulo 4: Resultados y Análisis

4.1. Cuantificación del problema de investigación

4.1.1. Heterogeneidad de maduración al momento de la cosecha

Los agricultores de aguacate tienen como práctica el realizar cosechas generalizadas del cultivo, por tanto se realizó una evaluación exploratoria en un cultivo de exportación en Fresno - Tolima (Reporte realizado en el anexo F), donde se determinó el contenido de materia seca de todos los frutos de un árbol en la temporada de cosecha. Como resultado se analizaron 146 frutos mediante métodos destructivos, y el histograma del contenido de materia seca se presta en la figura 4.1.




Figura 4.1: Histograma del número de frutos en relación con el contenido de materia seca para un árbol de aguacate "Hass", recién cosechado, en el semestre b de 2018, municipio de Fresno, Tolima. Los colores según la madurez para exportación: Amarillo = inmaduros, verde = maduros y naranja = sobremaduros.

La figura 4.1 muestra como el contenido de materia seca sigue una distribución normal, con un rango de madurez del 25 %. La madurez para exportación es entre 23.5 % a 30 % de materia seca (Astudillo-Ordóñez y Rodríguez, 2018). Por tanto, el 3 % de los frutos son inmaduros, el 23 % maduros, y el 74 % sobre maduros para exportación. Teniendo la posibilidad de que el productor lleve los frutos sobre maduros a un mercado nacional.

4.1.2. Dificultad de diagnóstico visual de la madurez del fruto recién cosechado

Los agricultores luego de realizar la cosecha generalizada realizan una clasificación de los frutos por apariencia externa y peso. Sin embargo, esta meto-

dología se refutó en el artículo del anexo B y se reportó un avance en el anexo F, para lo cual se aplicó la metodología de la sección 3.5.

Se recolectaron 706 frutos entre diciembre de 2018 y enero de 2020, en la misma finca y se midieron para cada fruto los valores cromáticos L, a y b de la cascara, el peso de cada fruto, y el contenido de materia seca. Llegando a la conclusión de que no hay correlación del contenido de materia seca de la fruta recién cosechada con las variables de color y peso de la fruta. Por lo tanto, la clasificación que realiza el agricultor no es efectiva.

4.2. Validación del método

Los resultados presentados hacen parte del artículo presentado en el anexo E y la metodología es la que se explica en la sección 3.4 y 3.5. Se analizaron 173 frutos, los cuales tenían un rango de materia seca entre 12,63 y 41,69%. Debido a que los frutos de aguacate son heterogéneos internamente (Woolf y cols., 2003) y el método propuesto no puede superar el método de laboratorio y las frutas no se clasifican en un rango intermedio, se decidió descartar los datos de 16 frutos porque no tenían un valor absoluto de madurez entre las muestras. Por lo tanto, se utilizaron los datos de 157 frutos en 454 imágenes, donde el 83% de las imágenes provienen de frutos inmaduros (menor a 23,5% de materia seca). Esta distribución es la más cercana a el ambiente relevante, en el que la mayoría de los frutos son inmaduros y el reto es identificar los frutos madurados.

Luego de optimizar un vector de descriptores de textura para cada origen de los datos, se calculó 100 veces con la maquina de soporte vectorial la precisión de clasificación en validación cruzada. La maquina de soporte vectorial se configuró con las variables de defecto del programa Matlab, un kernel lineal, y la validación cruzada de 10 grupos.

La Tabla 4.1 muestra que la precisión de todos los tratamientos es superior al 95%, con una tendencia a aumentar la precisión con un mayor número de canales y la corrección del histograma CLAHE. El valor máximo es una precisión promedio del 98,28%, por lo que se puede afirmar que el método propuesto es viable. El vector de descriptores estuvo entre 9 y 32 descriptores, lo cual puede afectar el costo computacional de la implementación. Sin em-

bargo, se selecciona el vector con mayor precisión promedio el cual permite asegurar el éxito del método.

Tabla 4.1: Precisión de la clasificación de frutos de aguacate "Hass", con maquina de soporte vectorial, en relación al origen de los datos para la optimización del vector de descriptores de textura. Se presenta: diferentes combinaciones del origen de los datos (H,S,V y Histo) , el promedio de 100 repeticiones (Media (%)), la desviación estándar de la clasificación en 100 repeticiones (Std), y el tamaño del vector de descriptores de textura optimizado.

H	S	V	Histo	Media (%)	Std	Vector
Si	No	No	No	95.54	0.17	9
No	Si	No	No	96.23	0.17	9
No	No	Si	No	96.00	0.20	7
Si	No	No	Si	95.59	0.39	28
No	Si	No	Si	96.46	0.14	5
No	No	Si	Si	96.68	0.18	18
Si	Si	No	Si	98.02	0.21	23
Si	No	Si	Si	96.86	0.26	28
No	Si	Si	Si	96.81	0.23	18
Si	Si	No	No	96.14	0.32	21
Si	No	Si	No	96.28	0.33	32
No	Si	Si	No	95.55	0.22	9
Si	Si	Si	No	96.26	0.40	32
Si	Si	Si	Si	98.28	0.26	30

Para evaluar la significancia de las fuentes de origen de los datos se realizó un análisis de varianza de cuatro factores con los datos de la tabla 4.1. Con este análisis se determinó que la corrección del histograma es significativo, con un valor de probabilidad inferior a 0,05. Por lo tanto, este proceso aumenta la precisión de la clasificación. Así mismo, el canal que aporta una mayor significancia es el de saturación. Estos resultados concuerdan con el método tradicional de asociar la madurez del fruto a la reducción en el brillo del mismo (Bernal y cols., 2014).

Finalmente, se selecciona el origen de datos con el que se obtiene mayor precisión de clasificación, el cual implica el uso de la corrección de histograma CLAHE y los datos de los canales H, S, y V. Los datos de las 100 repeticiones se presentan en la figura 4.2.a. Y se presenta en la figura 4.2.b la probabilidad dada por el clasificador de la pertenencia del vector a un fruto inmaduro en relación al contenido de materia de cada fruto, para un caso específico con una eficiencia de clasificación de 98.2379 %.

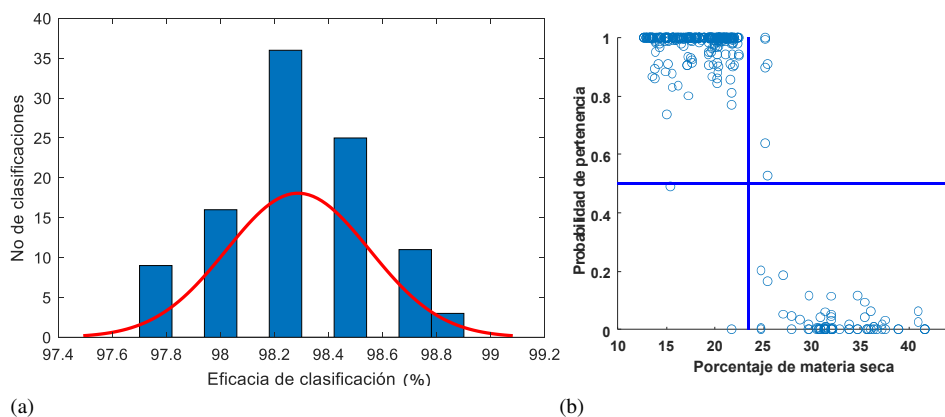


Figura 4.2: Eficacia de clasificación de aguacate "Hass" en el árbol, mediante el uso de una maquina de soporte vectorial entrenada con un vector de descriptores de textura optimizado a partir de un segmento de una imagen del fruto, con corrección de histograma y el uso de los canales H, S y V de la imagen. a) Histograma y ajuste de distribución de la eficiencia de clasificación con el vector seleccionado en 100 repeticiones. b) Gráfico de probabilidad dada por el clasificador de la pertenencia del vector a un fruto inmaduro Vs contenido de materia de cada fruto

Se puede analizar de la figura 4.2.a que la distribución de los resultados del clasificador tiene una distribución normal, y se encuentran en un rango de 97,8% a 98,8%. Así mismo se observa en la figura 4.2.b que el rango con mayores errores de clasificación se presenta con los frutos maduros de hasta 25% de materia seca, lo que plantea que hay un mayor error en la frontera de clasificación. Por lo tanto, se evaluaron otros métodos para generar la frontera de clasificación, realizando la optimización de vectores de descriptores de textura con diferentes configuraciones del kernel de la maquina de soporte vectorial. La eficacia de clasificación es el promedio de 100 repeticiones de la validación cruzada, los resultados se presentan en la tabla 4.2.

Tabla 4.2: Precisión de la clasificación de frutos de aguacate "Hass", usando maquina de soporte vectorial con diferentes configuraciones del kernel de la maquina de soporte vectorial para la optimización del vector de descriptores de textura, usando la fuente de datos con corrección de histograma y los canales H, S y V.

Función kernel	Promedio	Std	Vector
Linear	98.03	0.34	32
Gaussian	95.35	0.06	3
Radial basis function	95.61	0.18	4
Polynomial	94.81	0.19	34

Al analizar la tabla 4.2 se concluye que la configuración lineal es la mas eficiente. Sin embargo, es de destacar que en la función Gausiana se puede obtener una precisión promedio del 95% con solo tres descriptores, lo cual implicaría un menor costo computacional.

4.3. Proyección de los ingresos extra que genera la solución

La solución tiene dos pasos: primero, clasificar si un fruto está maduro o no. Y segundo, repetir el proceso en un período de tiempo. El proceso de clasificación implica evaluar todos los frutos del árbol y recoger sólo los maduros. El método se repite en un periodo tal como se propone en la figura 3.2 donde el rango de materia seca de 6,5 % es equivalente a 3,2 meses de maduración en el árbol, el cual sería el periodo de repetición del método. Por tanto, se agrupó la fruta en rangos de 6.5 % de materia seca, para exportación, tal como se muestra en la figura 4.3.

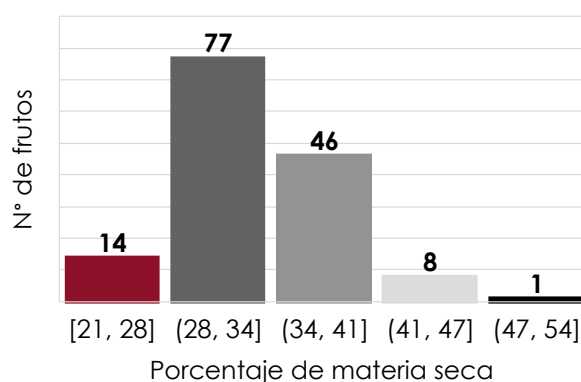


Figura 4.3: Histograma del número de frutos de un árbol de aguacate "Hass" en relación con el contenido de materia seca, agrupados en rangos de 6,5% de contenido de materia seca.

Tomando como base el caso de estudio, Al realizar el agrupamiento se obtienen cinco grupos de cosecha de frutos, y el proceso de clasificación implicaría evaluar todos los frutos para recolectar el grupo con madurez fisiológica, que en este caso sería un fruto. Pasado el periodo de repetición, se repite el procedimiento y se recolectaría el grupo de 8 frutos, así sucesivamente hasta recolectar el ultimo grupo de 11 frutos. Por tanto, si asumimos 20 segundos extras para evaluar cada fruto se calcula un total 2.961 horas por árbol. La proyección se se presenta en la tabla 4.3.

Tabla 4.3: Proyección del tiempo operacional extra en la implementación de la solución en un árbol

PASE	1	2	3	4	5	TOTAL
Frutos	1					
Frutos	8	8				
Frutos	46	46	46			
Frutos	77	77	77	77		
Frutos	14	14	14	14	14	
TOTAL FRUTOS	146	145	137	91	14	
Segundos (20/fruto)	2920	2900	2740	1820	280	
Horas	0.811	0.806	0.761	0.506	0.078	2.961

El tiempo operativo para la implementación de la solución en el árbol del estudio es un costo que se resta de los ingresos por venta de frutas. Si asumimos un productor que lleva la fruta hasta el mercado de destino, el método con la cosecha generalizada tendría venta de fruta a mercado nacional y mercado internacional. En cambio, con la solución propuesta el 98 % de la fruta cumpliría los requisitos del mercado internacional.

Tomando como referencia los precios de agosto de 2020, para el mercado nacional en la central mayorista de la plaza de corabastos, Bogotá D.C. con un valor de \$4.500/Kilo (Dane, 2020), y para el mercado internacional en Estados Unidos (InfoHASS, 2020), con un valor promedio de \$12745/kilo, se realiza la proyección de los ingresos de los dos métodos en la tabla 4.4.

Tabla 4.4: Proyección de los ingresos con el método actual y la solución planteada por árbol, para un agricultor exportador de aguacate "Hass".

Método	Tipo fruto	Nó	Peso Kg *	Precio/Kg **	Valor frutos	Clasificación ***	Ingresos - clasificación
Cosecha generalizada	Inmaduro	4	0.689	-	-		
	Maduro	34	5.856	12,745	74,632		158,336
	Sobre maduro	108	18.601	4,500	83,704		
Solución propuesta	Frutos total	143	24.629	12,745	313,895	- 10,832	303,063

* 0,172 Kg/fruto.

** Agosto 2020 (Dane, 2020; InfoHASS, 2020).

*** \$3658/Hora (2020).

Al comparar los ingresos menos el proceso de clasificación muestran que la solución permiten un incremento del 91.4 % de los ingresos del agricultor que realice todo el proceso de exportación de aguacate "Hass".

Capítulo 5: Producción

5.1. Productos

El proceso de formación doctoral se basó en dos ejes temáticos, el primero es el procesamiento de imágenes, enfatizado en el uso de descriptores de textura con métodos de aprendizaje de máquina. Otro eje, es el cultivo de aguacate y los problemas asociados a la cosecha. Por tanto, la producción presentada responde a alguno de estos ejes temáticos.

El primer documento es la solicitud de patente en la cual se presenta una invención que da respuesta a los dos ejes. El segundo documento es un artículo que demuestra la factibilidad de usar imágenes hiper-espectrales para medir el contenido de materia seca del aguacate "Hass" recién cosechado, y reporta que no hay correlación del color y el pesos con el contenido de materia seca del fruto. Este artículo divulga argumentos del problema central de la patente y combina los dos ejes. El tercer documento es un artículo que se basa en operadores estadísticos de los resultados de un algoritmo de textura usados para predecir el nivel de ruido de imágenes de textura, sin patrón de referencia. Este artículo presenta un método novedoso en este campo y se enmarca en el primer eje. El cuarto documento es un artículo como producto de la pasantía con la Universidad de Ghent, en el cual se proponen nuevos métodos para detectar paneles en imágenes térmicas en entornos complejos. En este artículo se usan métodos de corrección para entornos no controlados e incorpora clasificación con descriptores de textura, respondiendo al primer eje del doctorado. El quinto documento es un artículo en el que se reportan los resultados de la invención con datos en condiciones de laboratorio y directamente en el árbol, este da respuesta a los dos ejes temáticos. Finalmente, se presenta el resumen de una ponencia en un congreso internacional en el que se reportan los datos del problema de investigación y los avances de la predicción de la materia seca del aguacate con cámaras hiperespectrales, esta publicación se enmarca en los dos ejes del doctorado. El detalle de cada publicación se presenta en la tabla 5.1

Tabla 5.1: Productos

Clase de producto	Título	Medio de publicación	Clasificación	Fecha	Estado	Anexo
Patente	Método y dispositivo para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen	Superintendencia de industria y comercio	N/A	2020	Solicitud	A
Artículo	Prediction of dry matter content of recently harvested 'Hass' avocado fruits using hyperspectral imaging	Journal of the Science of Food and Agriculture Doi: 10.1002/jsfa.10697	Q1	2020	Publicado	B
Artículo	New method for inference of salt-and-pepper noise level from textured images, by statistical measures of residuals distribution in LBP images	Pattern Analysis and Applications (PAAA)	Q2	2020	Revisión de pares	C
Artículo	Solar panel detection within complex background using thermal images acquired by UAVs	Sensors Doi: 10.3390/s20216219	Q1	2020	Publicado	D
Artículo	Prediction of physiological maturity of "Hass" avocado by image texture descriptors	Postharvest biology and technology	Q1	2020	Sometido	E
Conferencia	Heterogeneidad en la madurez de los frutos de aguacate en el árbol y avances para su medición con imágenes hiperespectrales	CONGRESO INTERNACIONAL DE CIENCIA Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE HASS Y CACAO ISSN 2711-0982	N/A	2019	Publicado	F

Capítulo 6: Conclusiones

El cultivo de aguacate "Hass" en Colombia presenta heterogeneidad de maduración en el árbol, con un rango de materia seca de 25 %. Sin embargo, el rango de madurez para exportación es de 6.5 % de materia seca. Por tanto, si el agricultor quiere que toda su producción pueda ser exportada, necesita clasificar la fruta antes de ser cosechada.

Según los valores medidos en el caso de estudio, la clasificación de la madurez del fruto de aguacate Hass que toma como referencia su peso y color no es efectiva. Por lo tanto, las practicas realizadas por los agricultores Colombianos debería ser replanteada.

El uso de descriptores de textura de imágenes de la piel del aguacate, en formato RGB, sin compresión y resolución espacial homogénea sirven como referente para clasificar si un fruto tiene madurez fisiológica. Este método puede ser usado en el árbol o posterior a la cosecha, con la ventaja de no requerir condiciones de iluminación controladas.

Se determinó que el origen de los datos con mayor eficiencia de clasificación es el que: usa la ecualización de histograma adaptativo limitado por contraste, convierte la imagen RGB a HSV y usa los tres canales de un segmento del imagen HSV para calcular el vector optimizado de descriptores de textura. Con este método se optimizó un vector de 32 descriptores de textura, que al ser usados por una maquina de soporte vectorial con configuración lineal, presentó un promedio de eficiencia de clasificación en validación cruzada, en 100 repeticiones, de 98.28 %.

La clasificación de los frutos de aguacate "Hass" según su madurez fisiológica de forma iterativa, permite que el 98 % de la fruta recolectada esté en el rango de madurez de exportación. Homogeneizar la madurez de la fruta cosechada implicaría un aumento del 91.4 % los ingresos para un agricultor que implemente toda la cadena de exportación.

Partiendo de una propuesta de valor clara, para los productores exportadores, se proyecta que la presente invención puede tener un modelo económico

basado en: la venta de dispositivos para uso por parte de los agricultores, la venta de servicios de cosecha y servicios personalizados de integración de datos. En este sentido se identifican tres tipos de clientes: los agricultores pequeños, las asociaciones de agricultores y los agricultores grandes. Entre las relaciones con los clientes además de la venta del dispositivo o los servicios, se encuentra el proceso de parametrización del modelo. Para esto se requiere personal de contacto directo y vía telefónica con el cliente. El modelo de negocio según la metodología CANVAS se presenta en el anexo G.

En el anexo A se demuestra la factibilidad de patentar un método y un dispositivo que implemente el método propuesto.

En el trabajo reportado en el anexo B, se demostró que es posible predecir el contenido de materia seca de los frutos de aguacate con el uso de imágenes hiperespectrales, en condiciones de iluminación controladas. Con unas métricas de precisión en test de 0.9 para el R^2 , 2.6% M.S. para el error medio cuadrático y 0.95 para el coeficiente de correlación de Pearson.

En el trabajo reportado en el anexo C, Se demostró que el método propuesto con medidas estadísticas de residuales LBP para predecir el nivel de ruido de imágenes de texturas sin referencia es más eficiente que los métodos actuales.

En el trabajo reportado en el anexo D, Se demostró que es posible la detección de paneles solares en imágenes térmicas adquiridas con drones en entornos complejos. También, se demostró que el uso de máquinas de soporte vectorial en la clasificación de segmentos, obtenidos con métodos clásicos, en imágenes térmicas aumenta la eficiencia de predicción de paneles solares. Así mismo se demostró que el método novedosos para la proyección de paneles solares usando la geometría de los otros paneles detectados mejora la precisión, así se use en combinación con métodos clásicos o deep learning.

En el trabajo reportado en el anexo E, Además de demostrar que el método propuesto en esta tesis es viable. también, Se demostró que se puede clasificar la madurez del aguacate recién cosechado, usando imágenes RGB, en condiciones de laboratorio con iluminación controlada.

Bibliografía

- Addabbo, P., Angrisano, A., Bernardi, M. L., Gagliarde, G., Mennella, A., Nisi, M., y Ullo, S. (2017). A UAV infrared measurement approach for defect detection in photovoltaic plants. En *4th ieee international workshop on metrology for aerospace, metroaerospace 2017 - proceedings* (pp. 345–350). doi: 10.1109/MetroAeroSpace.2017.7999594
- Alcaraz, M. L., Thorp, T. G., y Hormaza, J. I. (2013, dec). Phenological growth stages of avocado (*Persea americana*) according to the BBCH scale. *Scientia Horticulturae*, *164*, 434–439. doi: 10.1016/j.scienta.2013.09.051
- Alcaraz Arco, M. L. (2009). *Biología reproductiva del aguacate (Persea americana Mill.). Implicaciones para optimización del cuajado*. (Tesis Doctoral, Universidad de Malaga). Descargado de http://www.avocadosource.com/international/spain_papers/AlcarazML2009b.pdf
- Alfaro-Mejía, E., Loaiza-Correa, H., Franco-Mejía, E., y Hernández-Callejo, L. (2020). Segmentation of Thermography Image of Solar Cells and Panels. *Communications in Computer and Information Science*, *1152 CCIS*, 1–8. doi: 10.1007/978-3-030-38889-8_1
- Alkhatib, M., y Hafiane, A. (2019). Robust Adaptive Median Binary Pattern for Noisy Texture Classification and Retrieval. *IEEE Transactions on Image Processing*, *28*(11), 5407–5418. doi: 10.1109/TIP.2019.2916742
- Al-Saedi, B., Alsaïdi, Jaffer Sadiq Al-khafaji, B., Abed, S., y Wahab, A. (2019). Content Based Image Clustering Technique Using Statistical Features and Genetic Algorithm. *Engineering, Technology and Applied Science Research*, *9*, 3892–3895.
- Alsafasfeh, M., Abdel-Qader, I., y Bazuin, B. (2017). Fault detection in photovoltaic system using SLIC and thermal images. En *Icit 2017 - 8th international conference on information technology, proceedings* (pp. 672–676). doi: 10.1109/ICITECH.2017.8079925
- Alsafasfeh, M., Abdel-Qader, I., Bazuin, B., Alsafasfeh, Q., y Su, W. (2018). Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision. *Energies*, *11*(9). doi: 10.3390/en11092252
- Al-Shamasneh, A. R., Jalab, H. A., Palaiahnakote, S., Obaidallah, U. H., Ibrahim, R. W., y El-Melegy, M. T. (2018). A new Local Fractional Entropy-Based model for kidney MRI image enhancement. *Entropy*, *20*(5). doi: 10.3390/e20050344
- Alvarez bravo, A., y Salazar-García, S. (2017). Las condiciones ambientales determinan la rugosidad de la piel del fruto de aguacate ‘Hass’. *Revista Mexicana de Ciencias Agrícolas*, *8*, 4063. doi: 10.29312/remexca.v0i19.673
- Amigo, J. M. (2020). Hyperspectral and multispectral imaging: setting the scene. *Data Handling in Science and Technology*, *32*, 3–16. doi: 10.1016/B978-0-444-63977-6.00001-8
- Amigo, J. M., y Santos, C. (2020). Preprocessing of hyperspectral and multispectral images. *Data Handling in Science and Technology*, *32*, 37–53. doi: 10.1016/B978-0-444-63977-6.00003-1
- AOAC International., P., y Cunniff, P. (1995). *Official methods of analysis of AOAC international* (16th ed. ed.). Washington DC: The Association. Descargado de <https://www.worldcat.org/title/official-methods-of-analysis-of-aoac-international/oclc/421897987>
- Arendse, E., Fawole, O. A., Magwaza, L. S., y Opara, U. L. (2018). Non-destructive prediction of internal and external quality attributes of fruit with thick rind: A review. *Journal of Food Engineering*, *217*, 11–23. doi: 10.1016/j.jfoodeng.2017.08.009
- Arpaia, M. L., Mitchell, F. G., Katz, P. M., y Mayer, G. (1987). Susceptibility of avocado fruit to mechanical damage as influenced by variety, maturity and stage of ripeness. *South African Avocado Growers Association Yearbook*, *10*, 149–151.
- Arzate-Vázquez, I., Chanona-Pérez, J. J., de Perea-Flores, M. J., Calderón-Domínguez, G., Moreno-Armendáriz, M. A., Calvo, H., ... Gutiérrez-López, G. (2011). Image Processing Applied to Classification of Avocado Variety Hass (*Persea americana* Mill.) During the Ripening Process. *Food and Bioprocess Technology*, *4*(7). doi: 10.1007/s11947-011-0595-6
- Astudillo-Ordóñez, C. E., y Rodríguez, P. (2018). Parámetros físicoquímicos del aguacate *Persea americana* Mill. cv. Hass (Lauraceae) producido en Antioquia (Colombia) para exportación. *Corpoica Ciencia y Tecnología Agropecuaria*, *19*, 383–392.
- Bernal, J., Díaz, C., Osorio, C., Tamayo, A., y Osorio, W. (2014). *Actualización tecnológica y buenas prácticas agrícolas (BPA) en el cultivo de aguacate*. Medellín: Corporación Colombiana de Investigación

Agropecuaria.

- Bhargava, A., y Bansal, A. (2018). Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University - Computer and Information Sciences*. doi: 10.1016/j.jksuci.2018.06.002
- Blakey, R. J. (2016). Evaluation of avocado fruit maturity with a portable near-infrared spectrometer. *Postharvest Biology and Technology*, 121, 101–105. doi: 10.1016/j.postharvbio.2016.06.016
- Brereton, R. G., y Lloyd, G. R. (2010). Support Vector Machines for classification and regression. *Analyst*, 135(2), 230–267. doi: 10.1039/b918972f
- Burdon, J., Lallu, N., Haynes, G., Francis, K., Patel, M., Laurie, T., y Hardy, J. (2015). Relationship between dry matter and ripening time in "hass" avocado. En *Acta horticulturae* (Vol. 1091, pp. 291–296).
- Burghouts, G. J., y Geusebroek, J.-M. (2009). Material-specific adaptation of color invariant features. *Pattern Recognition Letters*, 30(3), 306–313. doi: 10.1016/j.patrec.2008.10.005
- Carvalho, C., Velásquez, M., y Van Rooyen, Z. (2014). Determination of the minimum dry matter index for the optimum harvest of "Hass" avocado fruits in Colombia | Determinación del índice mínimo de materia seca para la óptima cosecha del aguacate "Hass" en Colombia. *Agronomía Colombiana*, 32(3). doi: 10.15446/agron.colomb.v32n3.46031
- Carvalho, C. P., y Velásquez, M. A. (2015). Fatty acid content of avocados (*Persea americana* Mill. cv. Hass) in relation to orchard altitude and fruit maturity stage | Contenido de ácidos grasos del aguacate (*Persea americana* Mill. cv. Hass) en relación a la altitud del cultivo y el estado de madur. *Agronomía Colombiana*, 33(2). doi: 10.15446/agron.colomb.v33n2.49902
- Cerdas Araya, M., Montero Calderón, M., y Somarribas Jones, O. (2014). Verificación del contenido de materia seca como indicador de cosecha para aguacate (*Persea americana*) Cultivar Hass en zona intermedia de producción de Los Santos, Costa Rica. *Agronomía Costarricense*, 38(1), 207–214. Descargado de <https://revistas.ucr.ac.cr/index.php/agrocost/article/view/15205>
- Chawla, R., Singal, P., y Garg, A. K. (2018). A Mamdani Fuzzy Logic System to Enhance Solar Cell Micro-Cracks Image Processing. *3D Research*, 9(3). doi: 10.1007/s13319-018-0186-7
- Chen, J., Lin, C., y Liu, C. (2018). The efficiency and performance detection algorithm and system development for photovoltaic system through use of thermal image processing technology. En *Aip conference proceedings* (Vol. 1978). doi: 10.1063/1.5044158
- Chen, M.-J., y Bovik, A. C. (2011). No-reference image blur assessment using multiscale gradient. *EURASIP Journal on Image and Video Processing*, 2011(1), 3. Descargado de <https://doi.org/10.1186/1687-5281-2011-3> doi: 10.1186/1687-5281-2011-3
- Cheng, J.-H., Nicolai, B., y Sun, D.-W. (2017). Hyperspectral imaging with multivariate analysis for technological parameters prediction and classification of muscle foods: A review. *Meat Science*, 123, 182–191. doi: 10.1016/j.meatsci.2016.09.017
- Chicco, D., y Jurman, G. (2020, jan). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21(1), 6. doi: 10.1186/s12864-019-6413-7
- Ciocca, G., Corchs, S., Gasparini, F., y Schettini, R. (2014). How to assess image quality within a workflow chain: an overview. *International Journal on Digital Libraries*, 15(1). doi: 10.1007/s00799-014-0124-0
- Clark, C. J., McGlone, V. A., Requejo, C., White, A., y Woolf, A. B. (2003). Dry matter determination in "Hass" avocado by NIR spectroscopy. *Postharvest Biology and Technology*, 29(3). doi: 10.1016/S0925-5214(03)00046-2
- Cokelaer, T., y Hasch, J. (2017). 'Spectrum': Spectral Analysis in Python. *Journal of Open Source Software*, 2(18), 348. doi: 10.21105/joss.00348
- Cowan, A. K., Taylor, N. J., y van Staden, J. (2005, jan). Hormone homeostasis and induction of the small-fruit phenotype in "Hass" avocado. *Plant Growth Regulation*, 45(1), 11–19. doi: 10.1007/s10725-004-7173-0
- Cristobal-Huerta, A., Poot, D. H. J., Vogel, M. W., Krestin, G. P., y Hernandez-Tamames, J. A. (2019). Compressed Sensing 3D-GRASE for faster High-Resolution MRI. *Magnetic Resonance in Medicine*, 82(3), 984–999. doi: 10.1002/mrm.27789
- Dane. (2020). *Sistema de Información de Precios SIPSA*. Descargado de <https://www.dane.gov.co/index.php/servicios-al-ciudadano/servicios-de-informacion/sipsa>
- Dávila-Sacoto, M., Hernández-Callejo, L., Alonso-Gómez, V., Gallardo-Saavedra, S., y González, L. G. (2020). Detecting Hot Spots in Photovoltaic Panels Using Low-Cost Thermal Cameras. *Communications in*

- Computer and Information Science, 1152 CCIS*, 38–53. doi: 10.1007/978-3-030-38889-8_4
- Denis Girod, M., Landry, J.-A., Doyon, G., y Osuna Garcia, J. A. (2008). Predicting Maturity of Hass Avocado Using Hyperspectral Imagery. *Caribbean Food Crops Society*, 44 (2), 27. Descargado de http://www.ars-grin.gov/may/documents/CFCS%7B_%7D2008.pdf
- Dixon, J., Lamond, C. B., Smith, D. B., y Elmsly, T. A. (2006). PATTERNS OF FRUIT GROWTH AND FRUIT DROP OF "HASS" AVOCADO TREES IN THE WESTERN BAY OF PLENTY, NEW ZEALAND. *New Zealand Avocado Growers' Association Annual Research Report*, 6, 47–54. Descargado de http://www.avocadosource.com/Journals/NZAGA/NZAGA_2006/NZAGA_2006_PG_47-54.pdf
- Dji. (2020). *Zenmuse XT specs*. Descargado de <https://www.dji.com/zenmuse-xt/specs>
- Donetti, M., y Terry, L. A. (2012). *Investigation of skin colour changes as non-destructive parameter of fruit ripeness of imported "hass" avocado fruit* (Vol. 945).
- Duda, R. O., Hart, P. E., y Stork, D. G. (2001). *Pattern Classification* (2.^a ed.). New York: Wiley.
- Edgar Roa Guerrero, y Gustavo Meneses Benavides. (2014, jun). Automated system for classifying Hass avocados based on image processing techniques. En *2014 iee colombian conference on communications and computing (colcom)* (pp. 1–6). IEEE. doi: 10.1109/ColComCon.2014.6860414
- Escobar, J. V., Rodríguez, P., Cortes, M., y Correa, G. (2019). Influence of dry matter as a harvest index and cold storage time on cv. Hass avocado quality produced in high tropic region. *Informacion Tecnológica*, 30(3), 199–210. doi: 10.4067/S0718-07642019000300199
- Espinosa-Velázquez, Dorantes-Alvarez, L., Gutiérrez-López, G. F., García-Armenta, E., Sánchez-Segura, L., Perea-Flores, M. J., ... Ortíz Moreno, A. (2016). Morpho-structural description of unripe and ripe avocado pericarp (*Persea americana* Mill var. *drymifolia*) | Descripción morfo-estructural del pericarpio del aguacate (*Persea americana* Mill var. *drymifolia*) inmaduro y maduro. *Revista Mexicana de Ingeniería Química*, 15(2).
- Estrada, B., y Alonso, J. (2016). *Estudios ecofisiológicos en aguacate cv. Hass en diferentes ambientes como alternativa productiva en Colombia* (Tesis Doctoral, Universidad Nacional, Medellín). Descargado de <http://www.bdigital.unal.edu.co/50844/>
- Faostat, F. (2020). Statistical databases. *Food and Agriculture Organization of the United Nations*. Descargado de <http://www.fao.org/faostat/es/#data/QC>
- Fernández Lozano, C. (2014). *Técnicas basadas en kernel para el análisis de texturas en imagen biomédica* (Tesis Doctoral, Universidade da Coruña). Descargado de <https://dialnet.unirioja.es/servlet/tesis?codigo=41514>
- Fleming, R. W. (2017). Material Perception. *Annual Review of Vision Science*, 3, 365–388. doi: 10.1146/annurev-vision-102016-061429
- Freitas, P. G., Da Eira, L. P., Santos, S. S., y De Farias, M. C. Q. (2018). On the application LBP texture descriptors and its variants for no-reference image quality assessment. *Journal of Imaging*, 4(10). doi: 10.3390/jimaging4100114
- Fuentealba, C., Pedreschi, R., Hernández, I., y Jorge. (2016). A STATISTICAL APPROACH FOR ASSESSING THE HETEROGENEITY OF HASS AVOCADOS SUBJECTED TO DIFFERENT POST-HARVEST ABIOTIC STRESSES. *Ciencia e investigación agraria*, 43(3), 2. doi: 10.4067/S0718-16202016000300002
- Ganesan, P., Xue, Z., Singh, S., Long, R., Ghoraani, B., y Antani, S. (2019). Performance Evaluation of a Generative Adversarial Network for Deblurring Mobile-phone Cervical Images. En *2019 41st annual international conference of the ieee engineering in medicine and biology society (embc)* (pp. 4487–4490). doi: 10.1109/EMBC.2019.8857124
- Gao, X., Munson, E., Abousleman, G. P., y Si, J. (2015). Automatic solar panel recognition and defect detection using infrared imaging. En *Automatic target recognition xxv* (Vol. 9476, p. 947600). doi: 10.1117/12.2179792
- Garrido, G., y Joshi, P. (2018). *OpenCV 3.x with Python By Example - Second Edition: Make the Most of OpenCV and Python to Build Applications for Object Recognition and Augmented Reality* (2nd ed.). Packt Publishing.
- Girod, D. (2008). *Détermination de la maturité des avocats Hass par imagerie hyperspectrale* (Tesis Doctoral, UNIVERSITÉ DU QUÉBEC). Descargado de http://espace.etsmtl.ca/137/1/GIROD_Denis.pdf

- Goring, S., Rao, R. R. R., y Raake, A. (2019). Nofu - A lightweight no-reference pixel based video quality model for gaming content. En *2019 11th international conference on quality of multimedia experience, qomex 2019*. doi: 10.1109/QoMEX.2019.8743262
- Greco, A., Pironti, C., Saggese, A., Vento, M., y Vigilante, V. (2020). A deep learning based approach for detecting panels in photovoltaic plants. En *Acm international conference proceeding series*. doi: 10.1145/3378184.3378185
- Gupta, M., Rajagopalan, V., y Rao, B. (2019). Glioma grade classification using wavelet transform-local binary pattern based statistical texture features and geometric measures extracted from MRI. *Journal of Experimental and Theoretical Artificial Intelligence*, 31(1), 57–76. doi: 10.1080/0952813X.2018.1518997
- Guyon, I., y Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *J. Mach. Learn. Res.*, 3, 1157–1182. Descargado de <http://dl.acm.org/citation.cfm?id=944919.944968>
- Haider, M., Doegar, A., y Verma, R. K. (2019). Fault identification in electrical equipment using thermal image processing. En *2018 international conference on computing, power and communication technologies, gucon 2018* (pp. 853–858). doi: 10.1109/GUCON.2018.8675108
- Henry, C., Poudel, S., Lee, S.-W., y Jeong, H. (2020). Automatic detection system of deteriorated PV modules using drone with thermal camera. *Applied Sciences (Switzerland)*, 10(11). doi: 10.3390/app10113802
- Hernández, I., Fuentealba, C., Olaeta, J. A., Lurie, S., Defilippi, B. G., Campos-Vargas, R., y Pedreschi, R. (2016). Factors associated with postharvest ripening heterogeneity of "Hass" avocados (*Persea americana* Mill). *Fruits*, 71(5), 259–268. Descargado de <http://www.pubhort.org/fruits/2016/5/fruits160045.htm> doi: 10.1051/fruits/2016016
- Herrera-González, J. A., Salazar-García, S., Martínez-Flores, H. E., y Ruiz-García, J. E. (2017). Preliminary signs of physiological maturity and postharvest performance of méndez avocado fruit | Indicadores preliminares de madurez fisiológica y comportamiento postcosecha del fruto de aguacate méndez. *Revista Fitotecnia Mexicana*, 40(1), 55–63. doi: 10.35196/rfm.2017.1.55-63
- Hoffmann, F., Bertram, T., Mikut, R., Reischl, M., y Nelles, O. (2019). Benchmarking in classification and regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(5). doi: 10.1002/widm.1318
- Hofman, P. J., y Jobin-Decor, M. (1999). Effect of fruit sampling and handling procedures on the percentage dry matter, fruit mass, ripening and skin colour of 'Hass' avocado. *Journal of Horticultural Science and Biotechnology*, 74(3), 277–282. doi: 10.1080/14620316.1999.11511108
- Hu, H., Huang, L., y Yu, W. (2019). Aircraft detection for hr sar images in non-homogeneous background using GGMD-based modeling. *Chinese Journal of Electronics*, 28(6), 1271–1280. doi: 10.1049/cje.2019.08.010
- Hu, X., Huang, Y., Gao, X., Luo, L., y Duan, Q. (2019). Squirrel-cage local binary pattern and its application in video anomaly detection. *IEEE Transactions on Information Forensics and Security*, 14(4), 1007–1022. doi: 10.1109/TIFS.2018.2868617
- Hunt, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S. T., Perry, E. M., y Akhmedov, B. (2013). A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21, 103–112. doi: <https://doi.org/10.1016/j.jag.2012.07.020>
- ICONTEC. (2003). NTC 5209. Aguacate. Variedades Mejoradas. Especificaciones. *Instituto Colombiano de Normas Técnicas y Certificación*, 26.
- InfoHASS. (2020). *Exportación a Estados Unidos*. Descargado de <http://www.infohass.net/>
- Ismail, H., Chikte, R., Bandyopadhyay, A., y Al Jasmi, N. (2019). Autonomous detection of PV panels using a drone. En *Asme international mechanical engineering congress and exposition, proceedings (imece)* (Vol. 4). doi: 10.1115/IMECE2019-12080
- Jaffery, Z. A., Dubey, A. K., Irshad, y Haque, A. (2017). Scheme for predictive fault diagnosis in photovoltaic modules using thermal imaging. *Infrared Physics and Technology*, 83, 182–187. doi: 10.1016/j.infrared.2017.04.015
- Jia, B., Wang, W., Ni, X., Lawrence, K. C., Zhuang, H., Yoon, S.-C., y Gao, Z. (2020). Essential processing methods of hyperspectral images of agricultural and food products. *Chemometrics and Intelligent Laboratory Systems*, 198. doi: 10.1016/j.chemolab.2020.103936
- Jiao, Y., Ijorra, O. M., Zhang, L., Shen, D., y Wang, Q. (2020). Curadiomics: A GPU-based radiomics feature extraction toolkit. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial*

- Intelligence and Lecture Notes in Bioinformatics*), 11991 LNCS, 44–52. doi: 10.1007/978-3-030-40124-5_5
- Kader, A. A. (1999, mar). FRUIT MATURITY, RIPENING, AND QUALITY RELATIONSHIPS. *Acta Horticulturae*(485), 203–208. Descargado de https://www.actahort.org/books/485/485_27.htm doi: 10.17660/ActaHortic.1999.485.27
- Kandavalli, M. A., y Abraham Lincon, S. (2019). Design and implementation of colour texture-based multiple object detection using morphological gradient approach. *Concurrency Computation*, 31(14). doi: 10.1002/cpe.4980
- Kas, M., El Merabet, Y., Ruichek, Y., y Messoussi, R. (2019). Survey on local binary pattern descriptors for face recognition. En *Acm international conference proceeding series*. Association for Computing Machinery. doi: 10.1145/3314074.3314079
- Krupiński, R. (2018). Modeling quantized coefficients with generalized gaussian distribution with exponent $1/m$, $m=2,3,\dots$ *Advances in Intelligent Systems and Computing*, 659, 228–237. doi: 10.1007/978-3-319-67792-7_23
- Lee, D., y Park, J. (2019). Development of Solar-Panel Monitoring Method Using Unmanned Aerial Vehicle and Thermal Infrared Sensor. En *Iop conference series: Materials science and engineering* (Vol. 611). doi: 10.1088/1757-899X/611/1/012085
- Lee, D. H., y Park, J. H. (2019). Developing inspection methodology of solar energy plants by thermal infrared sensor on board unmanned aerial vehicles. *Energies*, 12(15). doi: 10.3390/en12152928
- Lee, H. C., Kang, B. J., Lee, E. C., y Park, K. R. (2010, jul). Finger vein recognition using weighted local binary pattern code based on a support vector machine. *Journal of Zhejiang University SCIENCE C*, 11(7), 514–524. Descargado de <https://doi.org/10.1631/jzus.C0910550> doi: 10.1631/jzus.C0910550
- Lee, S., An, K. E., Jeon, B. D., Cho, K. Y., Lee, S. J., y Seo, D. (2018). Detecting faulty solar panels based on thermal image processing. En *2018 IEEE International Conference on Consumer Electronics, ICCE 2018* (Vol. 2018-Janua, pp. 1–2). doi: 10.1109/ICCE.2018.8326228
- Lee, S. K., y Young, R. E. (1983). *Growth Measurement as an Indication of Avocado Maturity* (Vol. 108; Inf. Téc. n.º 3). Descargado de http://www.avocadosource.com/Journals/ASHS/ASHS_1983_108_PG_395-397.pdf
- Lee Filters. (2020). *Technical Filters. 251 Quarter White Diffusion*. Descargado 2020-02-16, de <http://www.leefilters.com/lighting/colour-details.html#251>
- Li, B., Lecourt, J., y Bishop, G. (2018, jan). Advances in Non-Destructive Early Assessment of Fruit Ripeness towards Defining Optimal Time of Harvest and Yield Prediction - A Review. *Plants*, 7(1), 3. Descargado de <http://www.mdpi.com/2223-7747/7/1/3> doi: 10.3390/plants7010003
- Li, H., Hu, W., y Xu, Z.-N. (2016). Automatic no-reference image quality assessment. *SpringerPlus*, 5(1). doi: 10.1186/s40064-016-2768-2
- Liao, K. C., y Lu, J. H. (2020). Using Matlab real-time image analysis for solar panel fault detection with UAV. En *Journal of physics: Conference series* (Vol. 1509). doi: 10.1088/1742-6596/1509/1/012010
- Liu, L., Fieguth, P., Guo, Y., Wang, X., y Pietikainen, M. (2017). Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, 62, 135–160. doi: 10.1016/j.patcog.2016.08.032
- Liu, L., Zhao, L.-J., Guo, C.-Y., Wang, L., y Tang, J. (2018). Texture Classification: State-of-the-art Methods and Prospects. *Zidonghua Xuebao/Acta Automatica Sinica*, 44(4), 584–607. doi: 10.16383/j.aas.2018.c160452
- Liu, Z.-T., Li, S.-H., Cao, W.-H., Li, D.-Y., Hao, M., y Zhang, R. (2019). Combining 2D Gabor and local binary pattern for facial expression recognition using extreme learning machine. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 23(3), 444–455. doi: 10.20965/jaciii.2019.p0444
- López-Fernández, L., Lagüela, S., Fernández, J., y González-Aguilera, D. (2017). Automatic evaluation of photovoltaic power stations from high-density RGB-T 3D point clouds. *Remote Sensing*, 9(6). doi: 10.3390/rs9060631
- Ma, C., Lv, X., y Ao, J. (2019). Difference based median filter for removal of random value impulse noise in images. *Multimedia Tools and Applications*, 78(1), 1131–1148. doi: 10.1007/s11042-018-6442-2
- Ma, J., Sun, D.-W., Pu, H., Cheng, J.-H., y Wei, Q. (2019). Advanced techniques for hyperspectral imaging in the food industry: principles and recent applications. *Annual Review of Food Science and Technology*, 10, 197–220. doi: 10.1146/annurev-food-032818-121155

- Magwaza, L. S., y Tesfay, S. Z. (2015). A Review of Destructive and Non-destructive Methods for Determining Avocado Fruit Maturity. *Food and Bioprocess Technology*, 8(10). doi: 10.1007/s11947-015-1568-y
- Maier, A., y Rodriguez-Salas, D. (2017). Fast and robust selection of highly-correlated features in regression problems. En *Proceedings of the 15th iapr international conference on machine vision applications, mva 2017* (pp. 482–485). doi: 10.23919/MVA.2017.7986905
- Mandalapu, H., Ramachandra, R., y Busch, C. (2018). Image Quality and Texture-Based Features for Reliable Textured Contact Lens Detection. En *Proceedings - 14th international conference on signal image technology and internet based systems, sitis 2018* (pp. 587–594). doi: 10.1109/SITIS.2018.00095
- Marcante, N., de Mello Prado, R., Camacho, M., Rosset, J., Ecco, M., y Savan, P. (2010). Determination of dry matter and macronutrient content in leaves of fruit trees using different drying methods | Determinação da matéria seca e teores de macronutrientes em folhas de frutíferas usando diferentes métodos de secagem. *Ciencia Rural*, 40(11), 2398–2401.
- Markman, A., O'Connor, T., Hotaka, H., Ohsuka, S., y Javidi, B. (2019). Three-dimensional integral imaging in photon-starved environments with high-sensitivity image sensors. *Optics Express*, 27(19), 26355–26368. doi: 10.1364/OE.27.026355
- MATLAB. (2019a). *MATLAB and Image Processing Toolbox Release 2019b*. Descargado de https://la.mathworks.com/help/pdf_doc/images/rn.pdf
- MATLAB. (2019b). *Programming Fundamentals*. Descargado de https://la.mathworks.com/help/pdf_doc/matlab/matlab_prog.pdf
- Mazhar, M., Joyce, D., Hofman, P., y Vu, N. (2018). Factors contributing to increased bruise expression in avocado (*Persea americana* M.) cv. 'Hass' fruit. *Postharvest Biology and Technology*, 143, 58–67. doi: 10.1016/j.postharvbio.2018.04.015
- Md. Taha, A. Q., y Ibrahim, H. (2020). Reduction of salt-and-pepper noise from digital grayscale image by using recursive switching adaptive median filter. *Lecture Notes in Mechanical Engineering*, 32–47. doi: 10.1007/978-981-13-9539-0_4
- Medina-Carrillo, R. E., Salazar-García, S., Bonilla-Cárdenas, J. A., Herrera-González, J. A., Ibarra-Estrada, M. E., y Álvarez-Bravo, A. (2017). Secondary metabolites and lignin in "hass" avocado fruit skin during fruit development in three producing regions. *HortScience*, 52(6), 852–858. doi: 10.21273/HORTSCI11882-17
- Menéndez, O., Guamán, R., Pérez, M., y Cheein, F. A. (2018). Photovoltaic modules diagnosis using artificial vision techniques for artifact minimization. *Energies*, 11(7). doi: 10.3390/en11071688
- Ministerio de Agricultura y Desarrollo Rural. (2016). *ESTRATEGIA COLOMBIA SIEMBRA*. Descargado de <https://www.minagricultura.gov.co/planeacion-control-gestion/Gestin/ESTRATEGIACOLOMBIASIEMBRAV1.pdf>
- Ministerio de Agricultura y Desarrollo Rural. (2020). *Agronet. Estadísticas Agropecuarias*. Descargado de <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>
- Mittal, A., Soundararajan, R., y Bovik, A. C. (2013). Making a 'completely blind' image quality analyzer. *IEEE Signal Processing Letters*, 20(3), 209–212. doi: 10.1109/LSP.2012.2227726
- Mohana, y Ravish Aradhya, H. V. (2019). Simulation of object detection algorithms for video surveillance applications. En *Proceedings of the international conference on i-smac (iot in social, mobile, analytics and cloud), i-smac 2018* (pp. 651–655). Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/I-SMAC.2018.8653665
- Murthy, A. V., y Karam, L. J. (2010). A MATLAB-based framework for image and video quality evaluation. En *2010 2nd international workshop on quality of multimedia experience, qomex 2010 - proceedings* (pp. 242–247). doi: 10.1109/QOMEX.2010.5516091
- Nacereddine, N., Goumeidane, A. B., y Ziou, D. (2019). Unsupervised weld defect classification in radiographic images using multivariate generalized Gaussian mixture model with exact computation of mean and shape parameters. *Computers in Industry*, 108, 132–149. doi: 10.1016/j.compind.2019.02.010
- Nalepa, J., y Kawulok, M. (2019). Selecting training sets for support vector machines: a review. *Artificial Intelligence Review*, 52(2), 857–900. doi: 10.1007/s10462-017-9611-1
- Ncama, K., Magwaza, L. S., Poblete-Echeverría, C. A., Nieuwoudt, H. H., Tesfay, S. Z., y Mditshwa, A. (2018). On-tree indexing of 'Hass' avocado fruit by non-destructive assessment of pulp dry matter and oil content. *Biosystems Engineering*, 174, 41–49. doi: 10.1016/j.biosystemseng.2018.06.011

- New Zealand Avocados. (2018). *Regional Maturity Monitoring, Hass Avocados*. Descargado de http://industry.nzavocado.co.nz/industry/regional_maturity_monitoring.csn
- Ojala, T., Pietikainen, M., y Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1), 51–59. doi: [https://doi.org/10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4)
- Olarewaju, O. O., Bertling, I., y Magwaza, L. S. (2016). Non-destructive evaluation of avocado fruit maturity using near infrared spectroscopy and PLS regression models. *Scientia Horticulturae*, 199, 229–236. doi: [10.1016/j.scienta.2015.12.047](https://doi.org/10.1016/j.scienta.2015.12.047)
- Orjuela, S. A., Quinones, R. A., Ortiz-Jaramillo, B., Rooms, F., De Keyser, R., y Philips, W. (2011). Optimizing feature extraction in image analysis using experimented designs, a case study evaluating texture algorithms for describing appearance retention in carpets. En *Proceedings of spie - the international society for optical engineering* (Vol. 8136, p. 15). doi: [10.1117/12.893102](https://doi.org/10.1117/12.893102)
- Orjuela Vargas, S. A. (2013). *Texture analysis for the evaluation of appearance changes in textile surfaces* (Tesis Doctoral no publicada). Ghent University.
- Orjuela Vargas, S. A., Yañez, J. P., y Philips, W. (2014). The Geometric Local Textural Patterns (GLTP) technique. En S. Brahmam, L. C. Jain, L. Nanni, y A. Lumini (Eds.), *Local binary patterns : new variants and new applications* (Vol. 506, pp. 30–70). Springer. Descargado de <http://www.springer.com/engineering/computational+intelligence+and+complexity/book/978-3-642-39288-7>
- Orjuela-Vargas, S. A., Triana-Martinez, J., Yañez, J. P., y Philips, W. (2014). Real time algorithm invariant to natural lighting with LBP techniques through an adaptive thresholding implemented in GPU processors. En *Proceedings of spie - the international society for optical engineering* (Vol. 9023). doi: [10.1117/12.2042619](https://doi.org/10.1117/12.2042619)
- Osuna-García, J. J. A. J., Doyon, G., Salazar-García, S., Goenaga, R., y González-Durán, I. J. L. I. J. L. (2011, jan). Relationship between skin color and some fruit quality characteristics of "Hass" avocado. *Journal of Agriculture of the University of Puerto Rico*, 95(1-2), 15–23.
- Park, J., y Lee, D. (2019). Precise Inspection Method of Solar Photovoltaic Panel Using Optical and Thermal Infrared Sensor Image Taken by Drones. En *Iop conference series: Materials science and engineering* (Vol. 611). doi: [10.1088/1757-899X/611/1/012089](https://doi.org/10.1088/1757-899X/611/1/012089)
- Paul, S., y Bovik, A. C. (2019). Image Statistic Models Characterize Well Log Image Quality. *IEEE Geoscience and Remote Sensing Letters*, 16(7), 1130–1134. doi: [10.1109/LGRS.2019.2893363](https://doi.org/10.1109/LGRS.2019.2893363)
- Pedreschi, R., Muñoz, P., Robledo, P., Becerra, C., Defilippi, B., van Eekelen, H., ... De Vos, R. (2014a). Metabolomics analysis of postharvest ripening heterogeneity of 'Hass' avocados. *Postharvest Biology and Technology*, 92. doi: [10.1016/j.postharvbio.2014.01.024](https://doi.org/10.1016/j.postharvbio.2014.01.024)
- Pedreschi, R., Muñoz, P., Robledo, P., Becerra, C., Defilippi, B. G. B., van Eekelen, H., ... De Vos, R. C. R. (2014b, jun). Metabolomics analysis of postharvest ripening heterogeneity of "Hass" avocados. *Postharvest Biology and Technology*, 92, 172–179. doi: [10.1016/j.postharvbio.2014.01.024](https://doi.org/10.1016/j.postharvbio.2014.01.024)
- Phoolwani, U. K., Sharma, T., Singh, A., y Gawre, S. K. (2020). IoT Based Solar Panel Analysis using Thermal Imaging. En *2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science, SCEECS 2020*. doi: [10.1109/SCEECS48394.2020.114](https://doi.org/10.1109/SCEECS48394.2020.114)
- Pineda Tobón, D. M. (2017). *Diseño, construcción y evaluación de un fluorímetro y una cámara multiespectral para uso en agricultura y biología* (Maestría thesis, Universidad Nacional de Colombia - Sede Medellín.) Descargado de <http://bdigital.unal.edu.co/59275/1/1041148752.2017.pdf>
- Plutino, A., Lanaro, M. P., Liberini, S., y Rizzi, A. (2019). Work memories in Super 8: Searching a frame quality metric for movie restoration assessment. *Journal of Cultural Heritage*. doi: [10.1016/j.culher.2019.06.008](https://doi.org/10.1016/j.culher.2019.06.008)
- Pu, Y.-Y., Feng, Y.-Z., y Sun, D.-W. (2015). Recent progress of hyperspectral imaging on quality and safety inspection of fruits and vegetables: A review. *Comprehensive Reviews in Food Science and Food Safety*, 14(2), 176–188. doi: [10.1111/1541-4337.12123](https://doi.org/10.1111/1541-4337.12123)
- Rahman, M. M., Rahman, S., Kamal, M., Abdullah-Al-Wadud, M., Dey, E. K., y Shoyaib, M. (2016). Noise adaptive binary pattern for face image analysis. En *2015 18th international conference on computer and information technology, iccit 2015* (pp. 390–395). doi: [10.1109/ICCITechn.2015.7488102](https://doi.org/10.1109/ICCITechn.2015.7488102)
- Ravikanth, L., Jayas, D. S., White, N. D. G., Fields, P. G., y Sun, D.-W. (2017). Extraction of spectral information from hyperspectral data and application of hyperspectral imaging for food and agricultural products. *Food and Bioprocess Technology*, 10(1). doi: [10.1007/s11947-016-1817-8](https://doi.org/10.1007/s11947-016-1817-8)

- Rehman, T. U., Mahmud, M. S., Chang, Y. K., Jin, J., y Shin, J. (2019). Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Computers and Electronics in Agriculture*, 156, 585–605. doi: 10.1016/j.compag.2018.12.006
- Resonon. (2019). *SpectrononPro Manual 5.3*. Resonon Inc. Descargado de http://docs.resonon.com/spectronon/pika_manual/html/index.html
- Resonon. (2020). *Resonon, Pika XC2*. Descargado 2020-02-16, de <https://resonon.com/Pika-XC2>
- Richardson, A. D., Duigan, S. P., y Berlyn, G. P. (2002). An evaluation of noninvasive methods to estimate foliar chlorophyll content. *New Phytologist*, 153(1), 185–194. doi: 10.1046/j.0028-646X.2001.00289.x
- Rodriguez, A., Vargas, S. A. O., y Philips, W. (2013). Robust video feature extraction invariant to natural lighting by using LBP techniques with adaptive thresholding. En *Symposium of signals, images and artificial vision - 2013, stsiva 2013*. doi: 10.1109/STSIVA.2013.6644942
- Rodriguez, P., Henao, J. C., Correa, G., y Aristizabal, A. (2018). Identification of harvest maturity indicators for ‘hass’ avocado adaptable to field conditions. *HortTechnology*, 28(6), 815–821. doi: 10.21273/HORTTECH04025-18
- Sandilya, M., y Nirmala, S. R. (2018). Determination of reconstruction parameters in Compressed Sensing MRI using BRISQUE score. En *2018 international conference on information, communication, engineering and technology, icicet 2018*. doi: 10.1109/ICICET.2018.8533865
- Sanson, F., y Frueh, C. (2019). Noise estimation and probability of detection in non-resolved images: Application to space object observation. *Advances in Space Research*, 64(7), 1432–1444. doi: 10.1016/j.asr.2019.07.003
- Santana, I., Castelo-Branco, V. N., Guimarães, B. M., Silva, L. D. O., Peixoto, V., Cabral, L. M. C., ... Torres, A. G. (2019). Hass avocado (*Persea americana* Mill.) oil enriched in phenolic compounds and tocopherols by expeller-pressing the unpeeled microwave dried fruit. *Food Chemistry*, 286, 354–361. doi: 10.1016/j.foodchem.2019.02.014
- Schroeder, C. A. (1985). In: Physiological Gradient in Avocado Fruit. *Avocado Society Yearbook*, 562, 175–179. Descargado de <https://pdfs.semanticscholar.org/305a/d15c478bf4e812cc3d782cc606972b0372b5.pdf>
- Simon, P., y Uma, V. (2018). Review of texture descriptors for texture classification. En *Advances in intelligent systems and computing* (Vol. 542, pp. 159–176). doi: 10.1007/978-981-10-3223-3_{_}15
- Singh, R., Kushwaha, A. K. S., y Srivastava, R. (2019). Multi-view recognition system for human activity based on multiple features for video surveillance system. *Multimedia Tools and Applications*, 78(12), 17165–17196. doi: 10.1007/s11042-018-7108-9
- Subedi, P. P., y Walsh, K. B. (2020). Assessment of avocado fruit dry matter content using portable near infrared spectroscopy: Method and instrumentation optimisation. *Postharvest Biology and Technology*, 161. doi: 10.1016/j.postharvbio.2019.111078
- Sulas-Kern, D. B., Johnston, S., y Meydbray, J. (2019). Fill Factor Loss in Fielded Photovoltaic Modules Due to Metallization Failures, Characterized by Luminescence and Thermal Imaging. En *Conference record of the IEEE photovoltaic specialists conference* (pp. 2008–2012). doi: 10.1109/PVSC40753.2019.8980840
- Sun, W., y Du, Q. (2019). Hyperspectral band selection: A review. *IEEE Geoscience and Remote Sensing Magazine*, 7(2), 118–139. doi: 10.1109/MGRS.2019.2911100
- Tabatabaei, S. M., y Chalechale, A. (2019). Noise-tolerant texture feature extraction through directional thresholded local binary pattern. *Visual Computer*. doi: 10.1007/s00371-019-01704-8
- Tharwat, A. (2018). Classification assessment methods. *Applied Computing and Informatics*. doi: <https://doi.org/10.1016/j.aci.2018.08.003>
- Torres, I., y Amigo, J. M. (2020). An overview of regression methods in hyperspectral and multispectral imaging. *Data Handling in Science and Technology*, 32, 205–230. doi: 10.1016/B978-0-444-63977-6.00010-9
- Uma, J., Muniraj, C., y Sathya, N. (2019). Diagnosis of photovoltaic (PV) panel defects based on testing and evaluation of thermal image. *Journal of Testing and Evaluation*, 47(6). doi: 10.1520/JTE20170653
- Van Griethuysen, J. J. M., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., ... Aerts, H. (2017). Computational radiomics system to decode the radiographic phenotype. *Cancer Research*, 77(21), e104–e107. doi: 10.1158/0008-5472.CAN-17-0339
- Vega Diaz, J. J., Sandoval Aldana, A. P., y Reina Zuluaga, D. V. (2020). Prediction of dry matter content of recently harvested ‘Hass’ avocado fruits using hyperspectral imaging. *Journal of the Science of Food*

- and Agriculture, n/a(n/a). Descargado de <https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.10697> doi: 10.1002/jsfa.10697
- Venkatanath, N., Praneeth, D., Maruthi Chandrasekhar, B. H., Channappayya, S. S., y Medasani, S. S. (2015). Blind image quality evaluation using perception based features. En *2015 21st national conference on communications, ncc 2015*. doi: 10.1109/NCC.2015.7084843
- Walsh, K. B., Golic, M., y Greensill, C. V. (2004). Sorting of fruit using near infrared spectroscopy: Application to a range of fruit and vegetables for soluble solids and dry matter content. *Journal of Near Infrared Spectroscopy*, 12(3), 141–148. doi: 10.1255/jnirs.419
- Walsh, K. B., McGlone, V. A., y Han, D. H. (2020). The uses of near infra-red spectroscopy in postharvest decision support: A review. *Postharvest Biology and Technology*, 163. doi: 10.1016/j.postharvbio.2020.111139
- Wang, S., Zhang, Y., Nie, M., Zhao, Y., Yang, Z., Zhu, S., y Zhao, Y. (2019). Content-based image retrieval based on improved rotation invariant LBP descriptor. En *Proceedings - 2019 IEEE International Congress on Cybermatics: 12th IEEE International Conference on Internet of Things, 15th IEEE International Conference on Green Computing and Communications, 12th IEEE International Conference on Cyber, Physical and So* (pp. 1211–1216). doi: 10.1109/iThings/GreenCom/CPSCoM/SmartData.2019.00203
- Wang, Y. L., Sun, J., y Xu, H. W. (2014). Research on solar panels online defect detecting method. *Applied Mechanics and Materials*, 635-637, 938–941. doi: 10.4028/www.scientific.net/AMM.635-637.938
- Wedding, B., Wright, C., Grauf, S., White, R. D., Gadek, P. A., Wright, C., ... Gadek, P. A. (2011). Near infrared spectroscopy as a rapid non-invasive tool for agricultural and industrial process management with special reference to avocado and sandalwood industries. *Desalination and Water Treatment*, 32(1-3), 365–372. doi: 10.5004/dwt.2011.2723
- Wedding, B., Wright, C., Grauf, S., White, R. D., Tilse, B., y Gadek, P. (2013). Effects of seasonal variability on FT-NIR prediction of dry matter content for whole Hass avocado fruit. *Postharvest Biology and Technology*, 75. doi: 10.1016/j.postharvbio.2012.04.016
- Westad, F., y Marini, F. (2015). Validation of chemometric models – A tutorial. *Analytica Chimica Acta*, 893, 14–24. doi: <https://doi.org/10.1016/j.aca.2015.06.056>
- Wiki. (2020). *Canon Hack Development Kit (CHDK)*. Descargado de <https://chdk.fandom.com/wiki/CHDK>
- Woolf, A., Clark, C., Terander, E., Phetsomphou, V., Hofshi, R., Arpaia, L., ... White, A. (2003). Measuring avocado maturity ; ongoing developments. *Orchard*, 76(May), 40–45. Descargado de <http://209.143.153.251/Journals/%5CnOrchardist/WoolfAllan2003b.pdf>
- Wu, Y., Kirillov, A., Massa, F., Lo, W.-Y., y Girshick, R. (2019). *Detectron2*. Descargado de <https://github.com/facebookresearch/detectron2>
- Yang, L., Yang, Y., y Ma, Y. (2018). A novel no-reference video quality assessment algorithm. En *Proceedings of 2018 IEEE 4th Information Technology and Mechatronics Engineering Conference, ITOEC 2018* (pp. 181–187). doi: 10.1109/ITOEC.2018.8740719
- Yang, Y., Cai, X., Zhang, M., y Xiao, X. (2019). Reversible data hiding with different embedding capacity based on optimal embedding strategy selection and image quality assessment criteria. *Journal of Information Hiding and Multimedia Signal Processing*, 10(2), 392–407.
- Zheng, L., Shen, L., Chen, J., An, P., y Luo, J. (2019). No-Reference Quality Assessment for Screen Content Images Based on Hybrid Region Features Fusion. *IEEE Transactions on Multimedia*, 21(8), 2057–2070. doi: 10.1109/TMM.2019.2894939
- Zhu, L., Zhao, J., Fu, Y., Zhang, J., Shen, H., y Zhang, S. (2019). Deep learning algorithm for the segmentation of the interested region of an infrared thermal image. *Xi'an Dianzi Keji Daxue Xuebao/Journal of Xidian University*, 46(4), 107–114 and 121. doi: 10.19665/j.issn1001-2400.2019.04.015
- Zou, K. H., Tuncali, K., y Silverman, S. G. (2003). Correlation and simple linear regression. *Radiology*, 227(3), 617–622. doi: 10.1148/radiol.2273011499

Anexos

Anexo A: Solicitud de patente



El futuro
es de todos

Gobierno
de Colombia

BANDEJA DE ENTRADA >

NC2020/0011173 - Patente de Invención Nacional - MÉTODO Y DISPOSITIVO PARA DETERMINAR UN DATO DEL ESTADO DE MADUREZ FISIOLÓGICA DE UNA FRUTA A PARTIR DE DESCRIPTORES DE TEXTURA DE SU IMAGEN

Salir

Datos de la solicitud

Referencia del solicitante	P2020/000170	Fecha de radicación	09 sept. 2020
Número de patente	NC2020/0011173		
Estado	Bajo Verificación de Requisitos Mínimos		

Contacto

Apoderado	Número de identificación	Nombre(s)	Apellido(s)	Dirección (es)			
	79782747	CARLOS REINALDO	OLARTE GARCIA	Dirección Física : Carrera 5 N° 34-03 BOGOTÁ D.C. (CO)			
Solicitante(s)	Número de identificación	Nombre(s)	Apellido(s)	Dirección (es)			
	8600560707		UNIVERSIDAD ANTONIO NARIÑO	Dirección Física : Calle 58 A No. 37 - 94 Bogotá BOGOTÁ D.C. (CO)			
Contacto de la solicitud	Número de identificación	Nombre	Dirección	Ciudad	Código postal	País	Tipo de dirección
	79782747	CARLOS REINALDO OLARTE GARCIA	Carrera 5 N° 34-03	BOGOTÁ		CO	Dirección Física

Información de la Patente

Cerrar

Tipo de Patente	Patente de Invención Nacional			
Solicitud vía PPH	<input type="checkbox"/>			
Inventor(s)	Número de identificación	Nombre(s)	Apellido(s)	Dirección (es)
	19439502	RAFAEL MARÍA	GUTIÉRREZ SALAMANCA	Dirección Física : Carrera 3 Este No.47A-15, Bloque 4, Piso 3 BOGOTA CUNDINAMARCA (CO)
	80417160	Andres Ignacio	Hernández Duarte	Dirección Física : Carrera 3 Este No. 47 A-15, BOGOTA CUNDINAMARCA (CO)
	93400236	Sergio Alejandro	ORJUELA VARGAS	Dirección Física : Calle 4 #4-54 apto 805 torre 4 IBAGUE TOLIMA (CO)
	93413866	Jhon Jairo	VEGA DIAZ	Dirección Física : Manzana 45 Casa 4, Barrio Topacio IBAGUE TOLIMA (CO)
Cesión				
Título	MÉTODO Y DISPOSITIVO PARA DETERMINAR UN DATO DEL ESTADO DE MADUREZ FISIOLÓGICA DE UNA FRUTA A PARTIR DE DESCRIPTORES DE TEXTURA DE SU IMAGEN			
Título inicial	MÉTODO Y DISPOSITIVO PARA DETERMINAR UN DATO DEL ESTADO DE MADUREZ FISIOLÓGICA DE UNA FRUTA A PARTIR DE DESCRIPTORES DE TEXTURA DE SU IMAGEN			
Tiempo para la publicación	18			

Prioridad

Prioridad

Documentos

Descripción

1 Documento (s)

Documento	Tipo	Confidencialidad
Descripción	Descripción	Pública

Resumen

La presente invención se refiere un dispositivo y método para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, lo anterior sin tener que estar en contacto directo con la fruta y sin tener ningún tipo de ambiente controlado en contacto con la fruta. Particularmente, la presente invención obtiene una imagen de una fruta en un espacio de color Rojo, Verde, Azul (RGB), la cual procesa con un proceso de Ecuación de Histograma Adaptativo Limitado por Contraste (CLAHE) y luego la transforma al espacio de color Matiz,

[Cerrar](#)

Saturación, Valor (HSV). Luego, de la imagen en un espacio de color (HSV) se obtienen unos datos de textura a partir de unos descriptores de textura, dichos datos de texturas son clasificados por medio de un método de clasificación, que puede ser una máquina de soporte vectorial (SVM) para determinar si la fruta está madura.

Reivindicaciones

Número de Reivindicaciones Recuerde que:
 -El número de Reivindicaciones diligenciado deberá estar coherente con el contenido del documento anexo
 -A partir de la undécima Reivindicación, deberá presentar pago por cada una de ellas para que éstas sean tenidas en cuenta

18

Número de folios 0

Declaraciones

Declaración sobre el uso de Recursos Genéticos o Biológicos
 Declaro que el objeto de la presente solicitud de patente fue obtenido a partir de recursos genéticos o biológicos de los que cualquiera de los países miembros de la Comunidad Andina es país de origen.

Sí No

Nota: En caso afirmativo deberá anexar copia del contrato de acceso de recursos genéticos o productos derivados, o certificado o número de registro, expedido por la Autoridad competente.

Declaración sobre uso de Conocimientos Tradicionales
 Declaro que el objeto de la presente solicitud de patente fue obtenido a partir de conocimientos tradicionales de comunidades indígenas, afroamericanas o locales de países miembros de la Comunidad Andina.

Sí No

Nota: En caso afirmativo deberá anexar la licencia o autorización de uso de conocimiento tradicional, o certificado, o número de registro expedido por la Autoridad competente.

Declaración de documentos presentados durante el año de gracia
 Declaro que la invención fue divulgada por parte del inventor o causahabiente durante el año anterior a la fecha de presentación y/o prioridad de la presente solicitud de acuerdo con el Art. 17 de la Decisión 486.

Sí No

Nota: En caso afirmativo deberá anexar el documento que divulga el objeto de la invención durante el año de gracia.

Obtener Reporte PDF

Cra 13 No. 27-00 pisos 1, 3, 4, 5, 6, 7 y 10 PBX: (571)5870000 . Call center: (571)5920400 Línea gratuita nacional 018000-910165
 www.sic.gov.co . e-mail: contactenos@sic.gov.co . Bogotá D.C. - Colombia.

[Política de privacidad](#) | Política editorial | Créditos | Webmaster: contactenos@sic.gov.co :: Todos los derechos reservados 2008 - 2020

Cerrar

MÉTODO Y DISPOSITIVO PARA DETERMINAR UN DATO DEL ESTADO DE MADUREZ FISIOLÓGICA DE UNA FRUTA A PARTIR DE DESCRIPTORES DE TEXTURA DE SU IMAGEN

Campo de la invención

La presente invención se relaciona con métodos y dispositivos para determinar la madurez de una fruta a través del procesamiento de imágenes. Particularmente, determinar la madurez de la fruta a través de descriptores de textura obtenidos de su imagen.

Descripción del estado de la técnica

Es importante conocer el mejor momento para cosechar la siembra, con el objetivo de tener un producto de alta calidad que cumpla los estándares para consumo y también, para que no se pudra durante su transporte, en exhibición en puntos de venta o en su proceso de exportación. Uno de los factores más importantes para saber el mejor momento para cosechar es el estado de madurez fisiológica de la fruta. Cosechar antes o después que la fruta este madura afecta la calidad del producto a comercializar. Ahora bien, en ciertas frutas existe dificultad de determinar el estado de madurez fisiológica ya que no permiten una clasificación visual para conocer su estado de madurez, entre estas se encuentra el aguacate Hass.

En este caso en particular, el mejor enfoque para determinar la madurez fisiológica del aguacate Hass para la exportación, implica el uso de técnicas no destructivas directamente en el árbol. El uso de imágenes es un método potencialmente superior para determinar el momento óptimo de cosecha, ya que es rápido y menos costoso. Se conocen el uso de imágenes para inferir el contenido de materia seca de la fruta de aguacate, sin embargo, las investigaciones se han realizado en postcosecha. Existen estudios en frutas como manzanas, bananos, tomates y piñas para determinar el momento óptimo de cosecha mediante la técnica de procesamiento de imágenes visuales, enfatizado en medidas del color. Sin embargo, el color no sirve como parámetro de clasificación de la madurez fisiológica del aguacate.

Por todo lo anterior, existe la necesidad de encontrar un dispositivo y método para determinar la madurez fisiológica de frutos que sea invariable a la rotación e iluminación y que al tiempo sea rápido y menos costoso.

El estado de la técnica divulga en el documento CN109978822A un método de evaluación de madurez de banano basado en visión artificial, dicho método sigue las siguientes etapas: posicionar una región de interés de una imagen de la fruta a una distancia específica (entre 50 y 100 cm), en donde la imagen se puede obtener por medio de una cámara que maneje el espacio de color RGB. La imagen se procesa utilizando un método de filtrado y umbral de espacio. El borde de la imagen se calcula mediante el operador de gradiente. Luego, se

obtiene una medida estadística de color usando un clasificador bayesiano ingenuo sobre dicha región de interés de la imagen. En esta segunda etapa se hace una transformación del espacio de color RGB de la región de interés de la imagen a un espacio de color HSV. En la siguiente etapa, se obtienen unas características locales de distribución de la dirección del gradiente de la región de interés de la imagen utilizando una técnica estadística de análisis discriminante.

Luego, en una etapa siguiente, se obtiene una característica de textura local de la imagen, utilizando un algoritmo SVM (Support Vector Machine, en inglés) multi-clase de acuerdo con una característica de textura local que se basa en un modelo de discriminación características de madurez del banano basado en características de forma locales y que juzga el modelo de decisión.

Sin embargo, el documento CN109978822A solo menciona que el procesamiento se realiza post cosecha, enfocándose en la madurez de consumo, y además el método solo es aplicado en los canales H (matiz) y S (saturación) del espacio de color HSV.

El documento CN110736709A divulga un método no destructivo para determinar la madurez de arándanos que usa una red neuronal. El método comprende las etapas de: (1) recoger muestras de arándanos desde el período de coloración hasta el período de madurez completo de las frutas de arándanos, muestrear N veces, y recopilar simultáneamente información de la imagen en color de las frutas de arándanos antes de recogerlas en cada período para su uso posterior; (2) medir y registrar el contenido de clorofila en la cáscara de arándano; (3) preprocesar la imagen obtenida mediante un ajuste de la resolución de la imagen tomada en el paso (1), toma la imagen como muestra de entrenamiento, ingresa la imagen en una red de predicción de contenido de clorofila de arándano y procesa la entrada de datos de imagen en la red de predicción de contenido de clorofila de arándano adoptando un método de reducción de promedios en un proceso de entrenamiento y prueba de la imagen.

Luego en una etapa (4), se construye un conjunto de datos de predicción del contenido de clorofila: realizar el marcado del marco en la imagen procesada en el paso (3) mediante el uso de un script Label-Image, etiquetar la imagen en el período correspondiente utilizando el valor medido de clorofila de cada período, construir un conjunto de datos de predicción de contenido de clorofila, y dividir el conjunto de datos de predicción de contenido de clorofila en un conjunto de datos de entrenamiento y un conjunto de datos de prueba.

Por último, se realiza una etapa (5) de entrenamiento y prueba de un modelo de predicción de contenido de clorofila ingresando el marco de límite como información de marcado en una red de contenido de predicción de clorofila de arándano extrayendo características de arándano. El modelo de predicción genera un marco de límite de arándano correspondiente en función de las características generadas, mapeando información relevante del límite encuadre en un mapa de características de una imagen original. Para luego, convertir las características mapeadas de arándanos en vectores de características de alta dimensión,

utilizando dichos vectores como información de características para predecir el contenido de clorofila, mapeando el contenido de clorofila de salida y la madurez de las frutas usando un modelo de predicción de contenido de clorofila entrenado. Para finalmente juzgar la madurez del valor de mapeo actual a través de un valor de mapeo de resultado de predicción final después de mapear entre valores.

Sin embargo, el documento CN110736709A se limita al uso de descriptores de color, para caracterizar los cambios en la clorofila, y predecir la madurez de la fruta.

El documento WO2015121809 divulga un equipo y un método para la identificación de frutos por color y cosecha selectiva. El equipo comprende un sistema de adquisición de imágenes con unidad mínima de observación del cultivo a nivel de rama y fruto, un sistema de procesamiento de imágenes conectado al sistema de adquisición de imágenes, el cual genera una señal de desprendimiento de fruto, por medio de la comparación de las imágenes procesadas contra dos valores de umbral, en donde uno indica la presencia de frutos maduros y otro que indica el riesgo de desprender un fruto inmaduro. El equipo de WO2015121809 comprende un mecanismo de desprendimiento de frutos que desprende el fruto en un movimiento que describe una función evolvente acorde a la silueta del fruto; un mecanismo de recepción de los frutos conectado al mecanismo de desprendimiento, un sistema de control que controla al mecanismo de desprendimiento, el sistema de procesamiento de imágenes, y el sistema de adquisición de imágenes; y un sistema de alimentación de energía al equipo.

Particularmente, el método de WO2015121809 comprende las etapas de: (a) adquirir imágenes de los frutos en la rama; (b) almacenar las imágenes en una memoria; (c) preprocesar las imágenes con un filtrado para reducción de ruido y mejora de las imágenes; (d) convertir las imágenes de un espacio de color RGB a un espacio de color LUX mod; (e) umbralizar las variables U, y VLUX-modificado del espacio de color LUX mod obteniendo una imagen binaria y detectar los pixeles de frutos maduros e inmaduros; (f) contar los pixeles de frutos maduros e inmaduros; (g) detectar las zonas de interés, conforme a la posición sobre la rama que contiene los frutos indicada por la imagen; (h) determinar un valor de umbral de riesgo de desprender un fruto inmaduro "N" como un porcentaje de la totalidad de pixeles de la sección de la zona de interés; (i) determinar el riesgo de desprender un fruto inmaduro comparando el porcentaje de pixeles de frutos inmaduros de la sección de la zona de interés con el valor de umbral de riesgo de desprender un fruto inmaduro "N"; (j) genera una orden de activación y desprender el fruto dependiendo de las siguientes reglas: i) si el porcentaje de pixeles maduros es mayor al valor de umbral de riesgo de desprender un fruto inmaduro "N" y el riesgo de cosechar frutos inmaduros es menor que valor de umbral de riesgo de desprender un fruto inmaduro "N" se genera una orden de activación y se desprende el fruto de manera automática; y, ii) si el porcentaje de pixeles maduros es mayor al valor de umbral de riesgo de desprender un fruto inmaduro "N" y si el porcentaje de pixeles de frutos inmaduros de la zona de interés supera valor de umbral de riesgo de desprender un fruto

inmaduro "N" no se genera orden de activación y no se desprende el fruto maduro de manera automática sino de forma manual.

Sin embargo, el documento WO2015121809 se limita al uso de descriptores de color, para caracterizar los cambios de color que se presentan en el café, y así determinar si el café está madurado.

De otra parte, el documento Dubey, S.R, Jalal, A.S. (*"Fusing Color and Texture Cues to Categorize the Fruit Diseases from Images"*. International Journal of Computer Vision and Image Processing (IJCVIP). 4: 52-67 (2014)) divulga un método para la clasificación de enfermedades de la fruta y se valida experimentalmente. Este documento está basado en el procesamiento de imágenes usando los siguientes pasos: en el primer paso, se utiliza la técnica de agrupamiento de "*K-Means*" para la segmentación de defectos, en el segundo paso se extraen y fusionan las señales de color y textura de la imagen segmentada, y finalmente las imágenes se clasifican en una de las clases mediante el uso de un algoritmo SVM multi-clase. Particularmente, este documento divulga que las imágenes de las frutas se pueden obtener en el espacio de color (HSV), aunque mencionan que en su modalidad preferida las obtienen en RGB y luego se transforman en el espacio de color L^*a^*b .

Sin embargo, este documento no evalúa específicamente la madurez fisiológica de la fruta, sino se limita a detectar segmentos de la fruta en mal estado.

Por otro lado, el documento S.Arivazhagan et al (*"Fruit Recognition using Color and Texture Features"*. Journal of Emerging Trends in Computing and Information Sciences, VOL. 1, NO. 2, Oct 2010) divulga un sistema de reconocimiento de frutas que comprende las siguientes etapas: 1) obtener una imagen de fruta de entrada y convertirla al espacio de color HSV. 2) umbralizar en el componente S, 3) cerrar agujeros pequeños con un operador morfológico de cierre con un elemento de estructuración de disco, 4) encontrar el área de una región de interés a partir de una imagen binaria, y 5) recortar la región de interés y reemplace los valores binarios con la intensidad de píxel original.

Particularmente, este documento divulga que para la clasificación de las frutas se usan descriptores de color y de textura, y menciona que las imágenes de la fruta se convierten al espacio de color HSV y las características estadísticas como la media, la desviación estándar, la inclinación y la curtosis se derivan de los componentes H y S. Por lo tanto, habrá ocho características estadísticas de color para una imagen. El componente V está sujeto a la descomposición de un nivel utilizando la Transformación discreta de Wavelet y las características de co-ocurrencia tales como contraste, energía, homogeneidad local, sombra de agrupamiento y prominencia de agrupamiento se derivan de la matriz de concurrencia construida a partir de la sub-banda de aproximación. Además, este documento divulga que el sistema obtiene buenos resultados combinando los descriptores de color con los descriptores de textura para clasificar las frutas.

Sin embargo, este documento se limita a detectar que tipo de fruta se encuentra en la imagen. Además, este documento solo divulga la clasificación en frutas cosechadas que ya se encuentra maduras y listas para consumo.

Breve descripción de la invención

La presente invención se refiere a un método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende: a) ingresar al menos un dato descriptor de textura y unos datos de referencia del estado de madurez en una unidad de memoria de una unidad de cómputo; b) obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta por medio de un dispositivo de adquisición de imágenes; c) procesar la imagen obtenida en el paso (b), aplicando un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante la unidad de cómputo; d) transformar la imagen procesada del paso (c) a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación en la unidad de cómputo; e) obtener al menos un dato de textura con la unidad de cómputo aplicando un método para determinar descriptores de textura de acuerdo con el dato descriptor de textura ingresado en el paso (a) en al menos un canal de color Matiz (H), Saturación (S) o Valor (V) del espacio de color HSV de la imagen obtenida en la etapa (d); y f) obtener un dato de estado de maduración mediante un método de clasificación que toma como entrada los datos de textura obtenidos en el paso (e) y los datos de referencia del estado de madurez en la etapa (a).

Adicionalmente, la presente invención se refiere a un dispositivo para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende un dispositivo de adquisición de imágenes, dicho dispositivo de adquisición de imágenes permite obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta. Además, comprende una unidad de cómputo conectado al dispositivo de adquisición de imágenes.

Particularmente, la unidad de cómputo está configurada para: recibir al menos un dato descriptor de textura de frutas y unos datos de referencia del estado de madurez en una unidad de memoria a la que accede la unidad de cómputo; procesar la imagen en el espacio RGB aplicando un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante una unidad de cómputo; transformar la imagen procesada a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación en la unidad de cómputo; obtener unos datos de textura por medio de la unidad de cómputo aplicando un método de textura de acuerdo con el dato descriptor de textura ingresado, en al menos uno de los canales de la imagen obtenida; y obtener un dato de estado de maduración mediante un método de clasificación, el cual tiene en cuenta los datos de textura obtenidos y los datos de referencia del estado de madurez ingresados.

Breve descripción de las figuras

La FIG. 1 muestra un diagrama de bloques de una modalidad del dispositivo para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen que tiene una unidad de cómputo que incluye un procesador, una memoria temporal, una unidad de memoria y un módulo comunicaciones, dicha unidad de cómputo, se conecta con un dispositivo de adquisición de imágenes que cuenta con un módulo de comunicación.

La FIG.2 muestra una modalidad del dispositivo para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen que tiene una carcasa con tapa que aloja una unidad de cómputo y un módulo de alimentación, dicha unidad de cómputo se conecta con un dispositivo de adquisición de imágenes que se aloja en otra carcasa. Adicionalmente, el dispositivo ilustrado tiene un dispositivo de distanciamiento y un dispositivo interfaz de usuario de luz.

La FIG.3 muestra el dispositivo para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen de la FIG. 2, obteniendo una imagen de una fruta que se encuentra en un árbol.

La FIG. 4 muestra un diagrama de flujo de una modalidad de un método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen.

La FIG.5 muestra un diagrama de flujo de otra modalidad del método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, las cuales cuentan con etapas para determinar si la imagen corresponde a una fruta y si la imagen tiene una calidad adecuada.

La FIG. 6 muestra un diagrama de flujo de una modalidad de un método para seleccionar unos descriptores de textura y uno datos de referencia del estado de madurez.

Descripción detallada de la invención

La presente invención está dirigida a un dispositivo y a un método para determinar el estado de madurez fisiológica de una fruta a partir del procesamiento de imágenes, particularmente, en frutas antes de cosechar.

Es conveniente conocer si una fruta está madura antes de cosecharla, para obtener un producto óptimo para la venta. Ahora bien, los agricultores tienen problemas con algunas frutas para saber cuál es el momento óptimo para su cosecha, sobre todo en ciertas frutas

donde la clasificación visual no es efectiva para conocer el estado de madurez, un ejemplo de este tipo de frutas es el aguacate Hass.

Por lo anterior, varias de las modalidades de la presente invención usan descriptores de textura, los cuales permiten clasificar por su estado de madurez fisiológica a una imagen de una fruta, preferiblemente, en frutas antes de cosechar. Adicionalmente, de manera preferible el dispositivo de la presente invención es portable y fácil de usar para los agricultores.

Haciendo referencia a la FIG. 1, en una modalidad de la invención, el dispositivo para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende un dispositivo de adquisición de imágenes (1), dicho dispositivo de adquisición de imágenes permite obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta, preferiblemente, sin compresión de la imagen. Además, el dispositivo de esta modalidad comprende una unidad de cómputo (2) conectado al dispositivo de adquisición de imágenes (1).

Particularmente, la unidad de cómputo (2) está configurada para: recibir al menos un dato descriptor de textura de frutas y unos datos de referencia del estado de madurez en una unidad de memoria (3) a la que accede la unidad de cómputo (2); procesar la imagen en el espacio RGB aplicando un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante una unidad de cómputo (2); transformar la imagen procesada a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación en la unidad de cómputo; obtener unos datos de textura por medio de la unidad de cómputo aplicando un método de textura de acuerdo con el dato descriptor de textura ingresado, en al menos uno de los canales de la imagen obtenida; y obtener un dato de estado de maduración mediante un método de clasificación, el cual tiene en cuenta los datos de textura obtenidos y los datos de referencia del estado de madurez ingresados.

Un efecto técnico del dispositivo de la presente invención es clasificar una fruta sin necesidad de hacer ensayos destructivos, sin tener que estar en contacto directo con la fruta y sin tener ningún tipo de ambiente controlado. Además, el dispositivo de la presente invención permite determinar si la fruta está madura aun cuando la fruta está en el árbol.

La unidad de cómputo (2) puede tener una unidad central de procesamiento (CPU) (4) preferiblemente con integración a una unidad de procesamiento gráfico (GPU) que lleva a cabo las tareas de procesamiento como por ejemplo el procesamiento que se le hace a la imagen para aplicar el proceso de CLAHE, calculo y clasificación de los descriptores de textura. La unidad central de procesamiento (4) se puede seleccionar del grupo conformado por: microcontroladores, micro procesadores, DSCs (Digital Signal Controller por sus siglas en inglés), FPGAs (Field Programmable Gate Array por sus siglas en inglés), CPLDs (Complex Programmable Logic Device por sus siglas en inglés), ASICs (Application Specific Integrated Circuit por sus siglas en inglés), SoCs (System on Chip por sus siglas en

inglés), PSoCs (Programmable System on Chip por sus siglas en inglés), computadores, servidores, tabletas, celulares, celulares inteligentes, generadores de señales y combinaciones de los mismos.

La unidad de memoria (3) puede ser una memoria permanente que alberga los datos cargados por el usuario y generados por la unidad central de procesamiento (4).

Además, el dispositivo puede incluir una memoria temporal (5) en la cual se pueden almacenar datos generados por la unidad central de procesamiento (4) que tiene un tiempo de almacenamiento limitado. El uso de memorias temporales para el procesamiento de datos sirve para agilizar los tiempos de procesamiento.

Opcionalmente, la memoria temporal (5) puede albergar datos de forma permanente, de igual forma, la unidad de memoria (3) puede albergar datos temporales.

En una modalidad, la unidad de memoria (3) y la memoria temporal (5) hacen parte de una memoria con un arreglo de registro de memoria. Donde la unidad de memoria (3) y la memoria temporal (5) corresponden a registros de memorias en dicha memoria.

En el caso de la unidad de memoria (3) y la memoria temporal (5) pueden seleccionarse entre memorias RAM (memoria caché, SRAM, DRAM, DDR), memoria ROM (Flash, discos duros, SSD, EPROM, EEPROM, memorias ROM extraíbles (v.g. SD (miniSD, microSD, etc), MMC (MultiMedia Card), Compact Flash, SMC (Smart Media Card), SDC (Secure Digital Card), MS (Memory Stick), entre otras)), CD-ROM, discos versátiles digitales (DVD por las siglas en inglés de Digital Versatile Disc) u otro almacenamiento óptico, casetes magnéticos, cintas magnéticas, almacenamiento o cualquier otro medio que pueda usarse para almacenar información y a la que se puede acceder por el procesador. En los registros de memoria generalmente se incorporan instrucciones, estructuras de datos, módulos de programas informáticos. Algunos ejemplos de estructura de datos son: una hoja de texto o una hoja de cálculo, una base de datos, se debe entender por una base de datos a un conjunto de datos almacenados en un registro de memoria sistemáticamente para su posterior uso.

Por otro lado, la unidad de cómputo (2) se conecta con un módulo de comunicaciones que es un elemento de hardware acoplado a una unidad de cómputo, unidad de procesamiento, o módulo de procesamiento o un servidor, el cual está configurado para establecer comunicación por medio de enlaces de comunicación entre uno o más unidades de cómputo o servidores para intercambiar datos, comandos y/o etiquetas. El módulo de comunicaciones se selecciona del grupo que consiste de módulos de comunicación alámbricos, módulos de comunicación inalámbrico y módulos de comunicación alámbrico e inalámbrico.

Haciendo referencia a la FIG. 2, la unidad de cómputo (2) y el dispositivo de adquisición de imágenes (1) se conectan entre ellos por medio del módulo de comunicación (6) que es

alámbrico e inalámbrico, en este caso la unidad de cómputo (2) y el dispositivo de adquisición de imágenes (1) se conectan por un cable.

El módulo de comunicaciones inalámbrico usa una tecnología de comunicación inalámbrica que se selecciona del grupo conformado por Bluetooth, WiFi, Radio Frecuencia RF ID (por las siglas en inglés de Radio Frequency Identification), UWB (por las siglas en inglés de Ultra Wide B-and), estándar CALM (del inglés, Communications Access for Land Mobile), GPRS, Konnex o KNX, DMX (por sus siglas en inglés, Digital MultipleX), WiMax y tecnologías de comunicación inalámbricas equivalentes que sean conocidos por una persona medianamente versada en la materia y combinaciones de las anteriores.

El módulo de comunicaciones alámbricas tiene un puerto de conexión cableada que permite la comunicación con los dispositivos externos mediante un bus de comunicaciones, el cual se selecciona entre otros, del grupo conformado por I2C (del acrónimo de IIC Inter-Integrated Circuit), CAN (por las siglas en inglés de Controller Area Network), BUS RS-232, BUS RS-485, BUS-422, BUS-423, Ethernet, SPI (por las siglas en inglés de Serial Peripheral Interface), SCI (por las siglas en inglés de Serial Communication Interface), QSPI (por las siglas en inglés de Quad Serial Peripheral Interface), 1-Wire, D2B (por las siglas en inglés de Domestic Digital Bus), Profibus y otros conocidos por una persona medianamente versada en la materia.

Adicionalmente, la unidad de cómputo (2) se conecta a un dispositivo de cómputo externo (9) mediante el módulo de comunicaciones (6), en donde el dispositivo de cómputo externo (9) está configurado para enviar datos a la unidad de cómputo (2), por ejemplo, el dispositivo externo (9) envía los datos descriptores de textura y los datos de referencia del estado de madurez.

En un ejemplo particular, la unidad de cómputo (2) se conecta a un servidor mediante el módulo de comunicaciones (6), en donde el servidor está configurado para programar la unidad de cómputo (2).

Se debe entender como servidor, un dispositivo que tiene una unidad de procesamiento configurada para ejecutar una serie de instrucciones correspondientes a etapas o pasos de métodos, rutinas o algoritmos. Además, el servidor tiene un módulo de comunicaciones que permite establecer conexión con otros servidores o dispositivos computacionales.

Además, los servidores pueden conectarse entre sí, y conectarse con otros dispositivos computacionales a través de arquitecturas de servicios web y comunicarse por protocolos de comunicaciones como SOAP, REST, HTTP/HTML/TEXT, HMAC, HTTP/S, RPC, SP y otros protocolos de comunicaciones conocidos por una persona medianamente versada en la materia.

Similarmente, los servidores mencionados en el Capítulo Descriptivo de la presente invención pueden ser interconectados a través de redes como el internet, redes VPN, redes LAN, WAN, otras redes equivalentes o similares conocidas por una persona medianamente versada en la materia y combinaciones de estas. Estas mismas redes pueden conectar a la unidad de cómputo (2) a uno o más servidores.

Algunos de los servidores mencionados en el Capítulo Descriptivo de la presente invención pueden ser servidores virtuales o servidores físicos.

Cualquiera de los servidores de la presente invención puede incluir un módulo de memoria configurado para almacenar instrucciones que al ser ejecutadas por el servidor ejecuten una parte, o la totalidad de una o más etapas de cualquiera de los métodos aquí divulgados.

Por otro lado, el dispositivo de adquisición de imágenes (1) tiene al menos un sensor sensible al espectro visible o a otras porciones del espectro electromagnético empleado para capturar una imagen que se encuentra en un campo visual de dicho dispositivo de adquisición de imágenes (1). Dicho dispositivo de adquisición de imágenes (1) es el encargado de obtener las imágenes de la fruta, con las cuales se va a determinar el estado de madurez fisiológica de la fruta. Por lo anterior y para mejorar el procesamiento de dichas imágenes, el dispositivo de adquisición de imágenes (1) en algunos casos debe poder cumplir ciertas condiciones (v.gr. obtener imágenes sin compresión o imágenes con resolución espacial homogénea).

Por lo anterior, en una modalidad de la invención, el dispositivo de adquisición de imágenes (1) obtiene las imágenes en un formato sin compresión para evitar pérdidas en los cambios sutiles de la textura de la imagen. En un ejemplo particular, el dispositivo de adquisición de imágenes (1) puede obtener la imagen en formato TIFF.

Del mismo modo, el dispositivo de adquisición de imágenes (1) obtiene las imágenes con una resolución entre 0.1Megapíxeles a 40Megapíxeles, preferiblemente, 0.5 Megapíxeles a 10 Megapíxeles y aún más preferiblemente, entre 1 Megapíxeles a 3 Megapíxeles. El efecto técnico de obtener una imagen con una resolución entre 1Megapíxeles a 3Megapíxeles es que permite garantizar la caracterización de un área representativa de la superficie de la fruta a una distancia que permite realiza la recolección manual de la fruta (30 a 50 cm).

El dispositivo de adquisición de imágenes (1) se puede seleccionar del grupo conformado por cámaras compactas, cámaras APS (por las siglas en inglés de Advanced Photo System), cámaras réflex SLR (por las siglas en inglés de Single Lens Reflex), cámaras digitales, cámara TLR (por las siglas en inglés de Twin Lens Reflex), escáneres y combinaciones de estos. Por otro lado, la tecnología del elemento sensor de las cámaras se selecciona del grupo conformado por sensores CCD (por las siglas en inglés de Charge Coupled Device), CMOS (por las siglas en inglés de Complementary Metal-Oxide-Semiconductor) o híbrido

CCD/CMOS, que a su vez se puede seleccionar entre tecnología a color, monocromática, alta definición, alta sensibilidad, alta velocidad, entre otras.

Opcionalmente, el dispositivo de adquisición de imágenes (1) puede obtener imágenes con resolución espacial homogénea. Para lograrlo el dispositivo de adquisición de imágenes (1) puede contar con dispositivos externos a este para obtener la resolución espacial homogénea o, por el contrario, el mismo dispositivo de adquisición de imágenes (1) puede contar tener embebidos elementos que permitan obtener la resolución espacial homogénea.

Haciendo una referencia a la FIG. 2, el dispositivo de adquisición de imágenes (1) cuenta con un dispositivo de distanciamiento (14), el cual está configurado para medir la distancia entre el dispositivo de adquisición de imágenes (1) y la fruta; y enviar una señal de control al dispositivo de adquisición de imágenes (1) para que obtenga la imagen de acuerdo con una condición de distanciamiento predefinida.

Por otra parte, el dispositivo de adquisición de imágenes (1) puede contar con el dispositivo de distanciamiento (14) que cuenta con un dispositivo de visualización, en este caso el dispositivo de distanciamiento (14) está configurado para medir la distancia entre el dispositivo de adquisición de imágenes y la fruta; y envía la señal de control al dispositivo de visualización, el cual convierte la señal de control en unos datos de distancia que corresponden a la distancia entre el dispositivo de adquisición de imágenes (1) y la fruta, estos datos se muestran al usuario por medio del dispositivo de visualización. El usuario que conoce la condición de distanciamiento predefinida obtiene la foto cuando la distancia que muestra el dispositivo de visualización es igual a la condición de distanciamiento predefinida. Lo anterior permite obtener imágenes con resolución espacial homogénea. La condición de distanciamiento predefinida se puede seleccionar entre 0.2 metros a 5 metros.

Por otro lado, el dispositivo de adquisición de imágenes (1) cuenta con un aumento (zoom) que puede ser un aumento óptico, o un aumento digital o combinaciones de los anteriores, con el cual se puede obtener la resolución espacial homogénea al modificar el nivel del aumento del dispositivo de adquisición de imágenes (1).

En una modalidad de la invención, el dispositivo de adquisición de imágenes (1) cuenta con el aumento y el dispositivo de distanciamiento (14), en donde el dispositivo de distanciamiento (14) puede estar configurado para medir la distancia entre el dispositivo de adquisición de imágenes (1) y la fruta; y enviar una señal de control a la unidad de cómputo (2), la cual está configurada para generar unos datos de nivel de zoom a partir de la distancia entre el dispositivo de adquisición de imágenes (1) y la fruta, los cuales corresponden al valor numérico del nivel del zoom necesario para lograr una resolución espacial homogénea. El dispositivo de distanciamiento (14) se puede seleccionar del grupo conformado por sensor de distancia ultrasónica, un sensor de distancia laser (v.gr. Parallax Láser Rangefinder), sensores de distancias inductivos, sensores de distancia por cable, sensores de distancia

infrarrojos, sensores de distancia magnéticos, u otros sensores de distancias conocidos por una persona medianamente versada en la materia y combinaciones de los anteriores.

Los datos de nivel de zoom son enviados al dispositivo de adquisición de imágenes (1), en donde el aumento permite aplicar el nivel de zoom para enfocar la fruta y tomar la imagen de la fruta, para luego ser enviada a la a la unidad de cómputo (2) para su procesamiento.

Por otro lado, el dispositivo de adquisición de imágenes (2) puede contar con un dispositivo de autoenfoco, el cual realiza un enfoque automático a la fruta para que sin importar la distancia entre el dispositivo de adquisición de imágenes (2) y la fruta se obtenga una imagen con resolución espacial homogénea.

En una modalidad de la invención, el dispositivo de la presente invención puede contar con un sensor de posición, el cual está configurado obtener unos datos de posicionamiento, dichos datos de posicionamiento corresponden a la ubicación del dispositivo en un área determinada (v.gr. un campo de sembrado). Lo anterior permite realizar una ubicación de donde fueron obtenidas las imágenes de las frutas, en especial las frutas que se considera maduras.

El dispositivo de la presente invención puede contar con un dispositivo de interfaz de usuario (8) conectado a la unidad de cómputo (2) para informar al usuario que la fruta que se está evaluando está madura y, por consiguiente, está apta para ser cosechada. Por consiguiente, el dispositivo interfaz de usuario está configurado para activarse al recibir una orden de activación, en donde la unidad de cómputo (2) está configurada para generar la orden de activación cuando se obtiene el dato de estado de maduración. El dispositivo de interfaz de usuario (8) puede ser un indicador de luz, un reproductor de sonido, un motor vibrador, una interfaz visual que muestra una imagen, un dispositivo de realidad aumentada que muestra una imagen, entre otros.

Opcionalmente, el dispositivo de la presente invención puede comprender un dispositivo de interfaz de usuario (8) de luz configurado para encenderse al recibir una orden de activación, en donde la unidad de cómputo (2) está configurada para generar la orden de activación cuando obtiene el dato de estado de maduración.

Por otra parte, el dispositivo de la presente invención puede comprender un dispositivo de interfaz de usuario (8) de audio configurado para reproducir un mensaje indicando que la fruta está lista para cosechar al recibir una orden de activación, en donde la unidad de cómputo (2) está configurada para generar la orden de activación cuando obtiene el dato de estado de maduración.

Por otro lado, el dispositivo de la presente invención puede contar con un dispositivo de cosecha de frutas, el cual está configurado para cosechar la fruta una vez se reciba una orden de activación de cosecha, en donde la unidad de cómputo está configura para generar la orden

de activación de cosecha cuando obtiene el dato de estado de maduración. El dispositivo de cosecha cuenta con un controlador, un actuador conectado al controlador y un elemento de cosecha conectado al actuador.

El controlador recibe la orden de activación de cosecha y genera una señal de control que es enviada al actuador, dicho actuador se activa moviendo el elemento de cosecha para cosechar la fruta. En un ejemplo particular, el elemento de cosecha son unas tijeras que se conectan al actuador, en otro ejemplo particular, el elemento de cosecha son unos brazos robóticos que se conectan al actuador.

Por otro parte, el dispositivo de la presente invención puede contar con un módulo de alimentación, que es un dispositivo capaz de mantener una diferencia de potencial eléctrico entre dos o más terminales como los son las baterías no recargables y las baterías recargables que se pueden seleccionar como fuentes de energía. Haciendo referencia a la FIGS. 2 y 3, el dispositivo de adquisición de imágenes (1) y la unidad de cómputo (2) se conectan a un módulo de alimentación (7).

En un ejemplo particular, el módulo de alimentación es una batería recargable, la cual se selecciona del grupo de baterías recargables de iones de litio, por ejemplo, baterías LFP, baterías NMC, baterías Li-S, baterías LiPo y otras baterías equivalentes conocidas por una persona medianamente versada en la materia. Así mismo, el módulo de alimentación puede ser también sustituido por uno de baterías no recargables como, por ejemplo, baterías de zinc-carbono (batería seca), zinc-cloruro, baterías alcalinas, baterías de litio, baterías de litio-disulfuro de hierro, y otras baterías equivalentes conocidas por una persona medianamente versada en la materia.

El dispositivo de la presente invención puede incluir al menos una carcasa configurada para alojar elementos del dispositivo que necesiten algún tipo de protección como lo puede ser por ejemplo la unidad de cómputo (2) o el dispositivo de adquisición de imagen (1). En una modalidad de la invención, la unidad de cómputo (2) y el dispositivo de adquisición de (1) se alojan en una única carcasa.

Haciendo referencia a la FIGS. 2 y 3, en una modalidad de la invención, se observa como en una primera carcasa (10) con tapa (11) se aloja la unidad de cómputo (2) y el módulo de alimentación (7) y en una segunda carcasa (12) se dispone el dispositivo de adquisición de imágenes (1), el dispositivo de interfaz de usuario (8) de luz y el dispositivo de posicionamiento (14). Se observa también, que el dispositivo de adquisición de imágenes (1) se conecta a la unidad de cómputo (2) y al módulo de alimentación (7) por medio de los módulos de comunicación (6, 15) alámbrico por medio de un cable.

Ahora bien, las carcasas pueden estar configuradas para conectarse a un sistema de agarre (13), el cual se configura a su vez para sostenerse en el cuerpo del usuario o a otro elemento. Particularmente, el sistema de agarre (13) se conforma por bandas elásticas, correas ajustables, arnés de cabeza, maletas, entre otros.

Haciendo referencia a al FIGS. 2 y 3, la segunda carcasa (12) cuenta con unas ranuras por las cuales, se conecta el sistema de agarre (13) que en este caso son unas correas ajustables, por su lado, la primera carcasa (10) se aloja en una maleta que lleva puesta el usuario.

Con el dispositivo descrito anteriormente, la presente invención realiza un método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen. Con el cual, haciendo un procesamiento de una imagen de la fruta se obtiene un dato de estado de maduración de esta.

Haciendo referencia a la FIG. 4, en una modalidad de la invención, el método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende:

- a) ingresar al menos un dato descriptor de textura y unos datos de referencia del estado de madurez en una unidad de memoria (3) de una unidad de cómputo (2);
- b) obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta por medio de un dispositivo de adquisición de imágenes (1);
- c) procesar la imagen obtenida en el paso (b), aplicando un proceso de Ecuilibración de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante la unidad de cómputo (2);
- d) transformar la imagen procesada del paso (c) a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación en la unidad de cómputo (2);
- e) obtener al menos un dato de textura con la unidad de cómputo aplicando el descriptor de textura ingresado en el paso (a), en al menos un canal de color Matiz (H), Saturación (S) o Valor (V) del espacio de color HSV de la imagen obtenida en la etapa (d); y
- f) obtener un dato de estado de maduración mediante un método de clasificación entrenado, el cual tiene en cuenta unos datos de textura obtenidos en el paso (e) y los datos de referencia del estado de madurez en la etapa (a).

El método de la presente invención permite determinar el estado de madurez de la fruta a través de su imagen, sin necesidad de tener contacto con la fruta. Preferiblemente, para analizar frutas en las que su color no indica claramente su nivel de madurez (e.g. aguacate Hass), el método evita utilizar descriptores de color de la imagen, o los puede tomar como un descriptor de menor importancia que otros, por ejemplo, los descriptores de textura. Al usar al menos un descriptor de textura, se logra realizar una clasificación de una imagen solo por su textura.

En la etapa a), en la unidad de cómputo (2) se ingresan al menos un dato descriptor de textura y unos datos de referencia del estado de madurez, en donde los datos de referencia del estado de madurez pueden representar el valor numérico o valores numéricos que debe arrojar el descriptor de textura para considerar una fruta madura o inmadura. El dato descriptor de textura ingresado le indica a la unidad de cómputo (2) que descriptor de textura debe obtener y bajo que método de textura lo debe obtener.

El dato descriptor de textura utilizado puede ser seleccionado al azar por el usuario o se puede obtener por un método de selección con datos previos, también se puede seleccionar más de dato descriptor de textura es decir un arreglo de datos descriptor de textura. Dicho arreglo de datos descriptor de textura le indica a la unidad de cómputo (2) cuales descriptores de textura debe obtener y bajo que método de textura debe obtener cada descriptor de textura. El utilizar un arreglo de datos descriptores de textura mejora la eficiencia de la detección de la madurez de la fruta. En el caso que exista un arreglo de datos descriptores de textura, se tiene a su vez un arreglo de datos de referencia del estado de madurez, dicho arreglo de datos de referencia del estado de madurez por ejemplo es un vector que representa una función en un hiperplano vectorial.

Ahora bien y como se mencionó anteriormente, se puede hacer una selección del dato descriptor o del arreglo de datos descriptores de textura que mejor describan una imagen de una fruta, lo anterior es importante, porque las características de la fruta pueden variar por diferentes motivos. Por ejemplo, la zona geográfica en donde se está tomando la puede disminuir la efectividad de ciertos descriptores de texturas y aumentar la efectividad de otros descriptores de textura para determinar el estado de madurez de la fruta.

Los descriptores de textura se pueden seleccionar entre: energía, entropía, contraste, homogeneidad y correlación de los métodos de textura como suma y diferencia de histogramas o la matriz de Co-ocurrencia, énfasis a corto plazo (SRE, por sus siglas), énfasis a largo plazo (LRE, por sus siglas), No uniformidad de nivel de grises (GLN, por sus siglas en ingles), no uniformidad de longitud de ejecución,(RLN, por sus siglas en inglés), porcentaje de ejecución (RP, por sus siglas en inglés), énfasis de ejecución de bajo nivel de grises (LGRE, por sus en inglés), énfasis de ejecución de nivel de gris alto (HGRE, por sus siglas en ingles), énfasis de bajo nivel de grises de corto plazo (SRLGE, por sus siglas en ingles), corto plazo Énfasis de nivel de gris alto (SRHGE, por sus siglas en ingles), gris bajo de largo plazo nivel de énfasis (LRLGE, por sus siglas en ingles) y nivel de grises alto a largo plazo Énfasis (LRHGE), método Py-Radiomics, así como la Media, mediana, desviación estándar, skewness o curtosis del histograma generado por un método de textura.

Para el cálculo de anteriores descriptores de textura, la unidad de cómputo (2) puede contar con unos métodos de textura que se pueden seleccionar del grupo conformado por: histogramas de suma y diferencia (sum and difference histograms), matriz de co-ocurrencia (co-occurrence matrix), matriz de longitud de corrida de nivel de gris (GLRLM, por sus siglas

en inglés), patrón binario local (LBP, por sus siglas en inglés), medidas de textura de leyes, eigenfilter, filtro gabor (gabor filter), la pirámide gaussiana (the gaussian pyramid), modelos autorregresivos, The steerable pyramid, descomposición wavelet (wavelet decomposition), la técnica del espectro de poder (The Power spectrum technique), la distribución de Wigner (The Wigner distribution) y campo aleatorio de markov gaussiano (Gaussian markov random field) u otros métodos de textura conocidos por una persona medianamente versada en materia y combinaciones de las anteriores.

Por lo anterior, el método de la presente invención puede ejecutar diferentes métodos para seleccionar los datos descriptores de textura que mejor describen la imagen de la fruta.

En una modalidad de la invención, el método de selección es un proceso de aprendizaje supervisado, el cual es entrenado con descriptores de textura de imágenes de frutas clasificadas por su maduración. De forma general, la utilización de estos métodos para seleccionar los descriptores de textura permite aumentar la efectividad del método para determinar el estado de madurez de fisiológica.

Por otro lado, el usar procesos de aprendizaje supervisado permite que a medida que se vayan recolectado más imágenes, se pueda realizar una continua actualización de los descriptores de textura y los datos de referencia del estado de madurez.

También, es importante señalar que si el dispositivo de la presente invención cambia de localización geográfica existe la posibilidad de que unos primeros datos descriptores de textura y unos primeros datos de referencia del estado de madurez ingresado en la etapa a), pierdan efectividad, por lo que, preferiblemente, se seleccionarían unos segundos descriptores que mejor describan la imagen de la fruta en la nueva localización. Por ejemplo, el método en su etapa a) se ingresaron unos primeros datos descriptores de textura y unos primeros datos de referencia del estado de madurez, y se ejecutó las etapas de la b) a la f) para determinar la madurez de unas frutas ubicadas en una finca en las coordenadas 5°08'21.6" N, 75°06'22.5" W a 1900 metros sobre el nivel del mar, con una temperatura promedio de 20 °C, en este caso todas las frutas identificadas como maduras en efecto eran maduras, lo anterior se comprobó con análisis posteriores a las frutas identificadas.

Ahora bien, se ejecutó el método con los primeros datos descriptores de textura y datos de referencias para determinar la madurez de en frutas ubicadas en una finca en las coordenadas 5°06'19.9"N 75°01'01.9"W a 1420 metros sobre el nivel del mar, con una temperatura promedio de 23 °C, en este caso el método identificó unas frutas como maduras, sin embargo, luego de realizarles análisis posteriores se identificaron que dentro de las frutas maduras habían algunas frutas inmaduras. En este caso, unos segundos datos descriptores de textura y unos segundos datos de referencia del estado de madurez fueron ingresados y se determinó que todas las frutas identificadas como maduras correspondían a frutas maduras. Los segundos datos descriptores de textura y los segundos datos de referencia del estado de

madurez se seleccionaron por un método de selección que tuvo en cuenta las nuevas variables que correspondían en este caso a una nueva localización de la fruta.

Haciendo la referencia a la FIG. 5, el entrenamiento del método de selección del al menos un descriptor de textura y los datos de referencia del estado de madurez ingresado etapa (a), puede comprender las siguientes sub-etapas:

- a1) obtener un conjunto de imágenes en un espacio de color Rojo, Verde, Azul (RGB) de un conjunto de frutas por medio del dispositivo de adquisición de imágenes (1);
- a2) obtener de cada fruta del conjunto de frutas un dato de maduración correspondiente a una característica de maduración de la fruta;
- a3) asignar a cada imagen obtenida en la etapa a1) el dato de maduración correspondiente a una característica de maduración obtenido en la etapa a2);
- a4) clasificar las imágenes de las frutas de acuerdo con el dato de maduración y almacenarlas en la unidad de memoria (3);
- a5) procesar las imágenes RGB aplicando una Ecuación de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante la unidad de cómputo (2);
- a6) transformar las imágenes procesada a un espacio de color HSV mediante un proceso de transformación;
- a7) ingresar un conjunto de métodos de textura y aplicar cada uno de los métodos de textura ingresados, en los canales de la imagen obtenida en la etapa a6) para obtener un arreglo de datos de referencia del estado de madurez por medio de la unidad de cómputo (2); y
- a8) obtener al menos un descriptor de textura y unos datos de referencia del estado de madurez por medio de un método de selección a partir del arreglo de datos de referencia del estado de madurez y de la clasificación de las imágenes de la etapa a4).

El entrenamiento anterior del método de aprendizaje supervisado permite obtener al menos un descriptor de textura y a su vez los datos de referencia del estado de madurez con los cuales se realiza la determinación de la madurez de la fruta.

Opcionalmente, un usuario que realiza el entrenamiento obtiene el dato de maduración correspondiente a la característica de maduración de la etapa a2), se pueden obtener de cualquier tipo de método conocido por la persona mediana versada en la materia, por ejemplo, en el caso del aguacate para conocer los valores de porcentaje de materia seca se realiza un ensayo destructivo para el conjunto de aguacates.

En la etapa a3), el usuario que realiza el entrenamiento puede realizar una asignación a las imágenes tomadas en la etapa a1), la asignación se basa en la característica de maduración obtenida en la etapa a2), que se puede seleccionar del grupo conformado por porcentaje de materia seca, grados brix, contenido de aceite, características morfológicas, entre otros. En un ejemplo particular, la característica de maduración es el porcentaje de materia seca de la fruta.

La utilización del porcentaje de la materia seca como característica de maduración es importante, en especial en frutas donde esta característica es el referente para determinar el estado de maduración fisiológica como lo es por ejemplo el aguacate Hass. En un ejemplo particular, cuando la fruta que se está analizando es el aguacate Hass, el porcentaje de materia seca se puede seleccionar de en un rango entre 17 % y 36.5%, preferiblemente, el rango se encuentra entre 23.5% y 30%, en donde se considera la fruta madura si el valor es mayor al valor del porcentaje de materia seca seleccionado, este valor del porcentaje de materia seca seleccionado se le denomina índice de cosecha. Ahora bien, en un ejemplo particular, se selecciona como característica de maduración el porcentaje de materia seca y se define que este índice de cosecha para definir la madurez fisiológica de la fruta es de 23.5%. Por tanto, las imágenes que provienen de frutas con un valor inferior a 23.5% se clasifican como inmaduras y las imágenes que provienen de frutas con un valor superior a 23.5% se clasifican como maduras.

Opcionalmente, en la etapa a4) el usuario que realiza el entrenamiento clasifica las imágenes de las frutas de acuerdo con el dato de maduración y las almacena en la unidad de memoria (3). Es decir, en la unidad de memoria (3) clasifican entre imágenes de frutas maduras e imágenes de frutas inmaduras.

Opcionalmente, los datos obtenidos en las etapas a5) y a6) se guardan en la memoria temporal (5) para disminuir tiempos de procesamiento.

Para realizar una selección adecuada de los descriptores de textura, el método de selección de la etapa a7) puede tener en cuenta unos criterios de selección, los cuales se seleccionan del grupo conformado por un valor de probabilidad (P) de un análisis de varianza (ANOVA), correlación específica entre descriptores, costo computacional, eficacia de predicción en validación cruzada, zona climática y combinaciones de estos.

Opcionalmente, el criterio de selección es la separabilidad de la madurez fisiológica por el dato del descriptor de textura, en este caso el criterio de selección se representa por un valor de probabilidad (P) de un análisis de varianza (ANOVA), en donde dicho P es menor que 0.01. Se debe entender como separabilidad de la madurez a que existe una probabilidad de 0.99 de que el descriptor de texturas puede separar los datos en maduros e inmaduros.

El método de selección se puede seleccionar del grupo conformado por máquina de soporte vectorial (SVM, por sus siglas en inglés), clasificador de red neuronal artificial, clasificador k vecinos más próximos, clasificador de una red neuronal probabilística, clasificador de función de base radial, redes neuronales de retropropagación, árbol de decisión, entre otros. En una modalidad de la invención, el método de selección es una máquina de soporte vectorial (SVM) para clasificación binaria.

En una modalidad de la invención, las imágenes procesadas son almacenadas localmente, pero además son enviadas a un servidor, el cual puede estar configurado para aplicar las etapas a7) y a8) del entrenamiento del método de selección, con los que se obtiene unos segundos descriptores de textura y unos segundos datos de referencia del estado de madurez. Uno de los efectos de llevar a cabo parte del entrenamiento en el servidor es que permite reducir los requerimientos de cómputo del dispositivo usado en campo, seguridad de la información, depuración continua del modelo, generación de modelos generalizados o individualizados para diferentes regiones, asociación de la información con otros datos e integración a otros dispositivos, mejora de los modelos al implementar nuevos descriptores de textura o métodos de clasificación.

Una vez obtenidas el menos un descriptor de texturas y los datos de referencias del estado de madurez, en una etapa b) se obtiene una imagen en el espacio de color RGB de al menos una porción de la fruta por medio del dispositivo de adquisición de imágenes (1). La ventaja de tomar la imagen en el espacio de color RGB es el aprovechamiento de la masificación de los sensores Bayer que han llevado a un bajo costo de implementación y también la facilidad que tiene para convertirse en datos hexadecimales. Preferiblemente, la imagen obtenida en la etapa a) corresponde a la totalidad de un plano de la fruta, con lo cual se aumenta la efectividad de la determinación del estado de madurez.

Por otro lado, una vez obtenida la imagen de la etapa a) la unidad de cómputo (2) puede extraer un segmento de la imagen, por ejemplo, la unidad de cómputo (2) puede solo usar el segmento de la foto que corresponde a la parte central de la fruta. En un ejemplo particular, se toma un segmento central de la imagen con un tamaño de 600*600 píxeles. Uno de los efectos técnicos de tomar el segmento central de la imagen de la fruta es que permite tener la suficiente información para caracterizar la textura de la fruta y representa bajo costo computacional.

Adicionalmente, para evitar pérdida de tiempo en procesamiento de la unidad de cómputo (2), la presente invención puede contar con métodos de procesamiento de imagen para saber si al objeto al cual se le tomo una foto es una fruta o no. Haciendo referencia a la FIG. 6, entre la etapa (b) y la etapa (c) ocurre una etapa adicional una etapa de determinar con la unidad de cómputo (2) si la imagen obtenida en la etapa (b) corresponde a una fruta usando un método de procesamiento de imagen configurado para reconocer frutas, en donde en caso que se determine que la imagen sea una fruta se continua con la etapa (d) y en caso contrario, la unidad de cómputo (2) genera una orden de activación de objeto desconocido.

El método de reconocimiento de frutas puede utilizar un proceso de aprendizaje supervisado que tiene en cuenta algunas características de la imagen como lo pueden ser los descriptores de textura, descriptores de color entre otro, para así determinar si la imagen es una fruta, u opcionalmente, identificar qué tipo de fruta es, el proceso de aprendizaje supervisado se puede seleccionar que se puede seleccionar del grupo conformado por máquina de soporte

vectorial, clasificador de red neuronal artificial, clasificador k vecinos más próximos, clasificador de una red neuronal probabilística, clasificador de función de base radial, redes neuronales de retropropagación, redes neuronales convolucionales, árbol de decisión, entre otros.

En un ejemplo particular, el método de procesamiento de imagen configurado para reconocer frutas sigue las siguientes etapas: obtener un dato de reconocimiento seleccionado entre un dato de validación y un dato de rechazo mediante la unidad de cómputo (2) ejecutando un proceso de aprendizaje automático de reconocimiento de imágenes que toma como entrada la imagen de la etapa b) y un arreglo de datos de entrenamiento que tiene imágenes de frutas e imágenes que no son frutas, donde el proceso de aprendizaje de reconocimiento de imágenes obtiene un dato de validación si la imagen de la etapa b) coincide con un dato del arreglo de datos de entrenamiento que representan frutas, de lo contrario, obtiene un dato de rechazo.

Del mismo modo, la unidad de cómputo (2) puede contar con un método procesamiento de imagen, el cual está configurado para determinar la calidad de imagen que es enviada a la unidad de cómputo (2), lo cual permite una correcta determinación del estado de madurez de la fruta a través de la imagen. Haciendo referencia a la FIG. 4, entre la etapa (b) y la etapa (c) ocurre una etapa adicional de determinar si la imagen tomada tiene una distorsión menor del 5%, la distorsión de la imagen se determina usando un método de la calidad de imagen, en caso que la distorsión de la imagen sea de menos del 5% se continúa con la etapa (d) y en caso contrario, la unidad de cómputo (2) genera un orden de activación de mala calidad de imagen.

En un ejemplo particular, el método de procesamiento de imagen para determinar calidad de imagen sigue las siguientes etapas: duplicar la imagen obtenida en la etapa b), aplicar diferentes filtros de distorsión en la imagen duplicada, extraer con diferentes algoritmos los bordes de la imagen obtenida en la etapa b) y en la imagen duplicada; dividir el número de bordes de la imagen obtenida en la etapa b) y en la imagen duplicada para cada algoritmo extractor de bordes; clasificar con un clasificador entrenado si es una imagen nítida o no. Si la imagen se clasifica como nítida entonces se continúa con la etapa c). Para el entrenamiento del clasificador se utiliza una base de datos de imágenes de frutas nítidas y frutas borrosas, a las cuales a cada se les aplicó el mismo método de procesamiento de imagen para determinar calidad de imagen antes descrito.

El método de calidad de imagen se selecciona del grupo conformado por métodos basado en píxeles (NR-P), Paramétrico/Métodos Bitstream (NR-B), Métodos híbridos (Hybrid NR-PB), entre otros.

En una modalidad de la invención, el método de reconocimiento de frutas y el método de calidad de imagen se realiza de manera simultánea. En otra modalidad de la invención, el

método de reconocimiento de frutas se realiza primero que el método de calidad de imagen. Del mismo modo, en otra modalidad de la invención el método de calidad de imagen se realiza primero que el método de reconocimiento de frutas. Un efecto técnico de que el método de calidad se lleve a cabo en primer lugar es que evita fallas en el procedimiento de reconocimiento de frutas, ya que este es entrenado con fotos nítidas.

Por su lado, en la etapa b) se obtiene una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta por medio de un dispositivo de adquisición de imágenes (1). Donde como se mencionó anteriormente, la imagen preferiblemente es una imagen sin compresión y con una resolución espacial homogénea. Por lo anterior, la etapa b) puede contar con unas subetapas para garantizar que se obtengan imágenes con resolución espacial homogénea, b1) medir la distancia entre el dispositivo de adquisición de imágenes (1) que cuenta con aumento y la fruta mediante el dispositivo de distanciamiento (14) y generar una señal de control; b2) enviar una señal de control a la unidad de cómputo (2); b3) generar unos datos de nivel de aumento a partir de la distancia entre el dispositivo de adquisición de imágenes (1) y la fruta, los cuales corresponden al valor numérico del nivel del aumento necesario para lograr una resolución espacial homogénea; y b4) enviar los datos de nivel de aumento al dispositivo de adquisición de imágenes (1), en donde el aumento del dispositivo de adquisición de imágenes (1) permite aplicar el nivel de aumento para enfocar la fruta y tomar la imagen de la fruta, para luego continuar con la etapa c).

En la etapa c) se procesa la imagen obtenida en la etapa (b), aplicando un proceso CLAHE mediante la unidad de cómputo (2). La utilización del proceso de CLAHE permite que se mejore la determinación el estado de madurez de la fruta, ya que realiza un ajuste del histograma por zonas, siendo un primer pasos para eliminar defectos de iluminación, lo anterior se comprobó realizando pruebas usando el método descrito, sin y con CLAHE y se notaron que en las imágenes procesadas usando los tres canales HSV con el proceso CLAHE fueron más efectiva (98.02%) en comparación con las imágenes procesadas usando los tres canales HSV sin el proceso CLAHE (94.82%).

Existe diferentes métodos para aplicar el proceso CLAHE de la etapa c) en una imagen, en un ejemplo particular, en la etapa c) se llevan a cabo las siguientes subetapas:

- c1) transformar la imagen a un espacio de color l^*a^*b ;
- c2) escalar unos valores a unos rangos esperados para la Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE);
- c3) aplicar una Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) en el canal l y escalar el resultado para volver al rango utilizado por el espacio de color $l^* a^* b$;
- c4) transformar la imagen resultante nuevamente en el espacio de color RGB.

Particularmente, en la etapa c2) el hace un escalamiento del valor del canal L de 0 a 1 y en la etapa c3) se multiplica el resultado por 100 para volver al rango utilizado por el espacio de

color $I * a * b$. El método descrito corresponde al método sugerido con la función `adapthisteq` por Matlab.

Por otra parte, en la etapa d) se transforma la imagen procesada del paso (c) a un espacio de color HSV mediante un proceso de transformación en la unidad de cómputo (2), en donde el proceso de transformación es una transformación matemática estándar que lleva a cabo la unidad de cómputo (2). Uno de los efectos técnicos del usar en el método el espacio de color HSV es que el nivel de madurez en algunas frutas no corresponde al color, por tanto, se transforman los datos a otro espacio en el que se evalúa la relación de los píxeles tomando como base el matiz, la saturación y el brillo de la imagen original, esta relación entre píxeles o textura no necesariamente es una representación de la rugosidad del fruto, sino que representan otras propiedades de la fruta que no son perceptibles visualmente.

Opcionalmente, los datos obtenidos en las etapas c) y d) se guardan en la memoria temporal (5) para disminuir tiempos de procesamiento.

Por su lado, en la etapa e) se aplica el descriptor de textura ingresado en el paso (a), en al menos uno de los canales de color Matiz (H), Saturación (S) o Valor (V) del espacio de color HSV de la imagen obtenida en (d) para obtener unos datos de textura mediante la unidad central de procesamiento (4) de la unidad de cómputo. En un ejemplo particular, se aplica el descriptor de textura ingresado en el paso (a) en el canal S, en el cual se representa el brillo de la fruta. Por otro lado, se aplica el descriptor de textura ingresado en el paso (a) en los tres canales HSV, lo cual mejora la efectividad de la determinación del estado de madurez de la fruta.

Por otra parte, en la etapa f), se obtiene un dato de estado de maduración mediante un método de clasificación entrenado, el cual tiene en cuenta unos datos de textura obtenidos en el paso (e) y los datos de referencia del estado de madurez en la etapa (a).

En una modalidad de la invención, el método de clasificación es un método de aprendizaje supervisado, el cual es entrenado con los datos de referencia del estado de madurez que representan los estados de madurez de la fruta calculados bajo un descriptor de textura o unos descriptores de textura determinados. Estos descriptores de textura o descriptor de textura corresponden a los ingresados en la etapa a).

El método de clasificación se puede seleccionar del grupo conformado por máquina de soporte vectorial (SVM, por sus siglas en inglés), clasificador de red neuronal artificial, clasificador k vecinos más próximos, clasificador de una red neuronal probabilística, clasificador de función de base radial, redes neuronales de retropropagación, árbol de decisión, entre otros.

En un ejemplo particular, el método de clasificación es una máquina de soporte vectorial (SVM) para clasificación binaria. Dicha máquina de soporte vectorial clasifica la imagen de la fruta obtenida entre madura y no madura, generando el dato de estado de maduración. En este ejemplo particular, los descriptores de textura y datos de referencia del estado de madurez ingresado en la etapa (a) forman una matriz de vectores que modela la máquina de soporte vectorial para clasificar la madurez de una fruta usando como referencia los descriptores de textura de la imagen en espacio de color HSV.

Opcionalmente, una vez se genera el dato de estado de maduración, este se asocia a un dato de posicionamiento obtenido por un sensor de posición, formando un arreglo de datos de mapeo, los cuales se almacenan en la unidad de memoria (3) de la unidad de cómputo (2). Dichos arreglos de datos mapeo permiten generar mapas de

Ahora bien, una vez generado el dato de estado de maduración mediante el método de clasificación en la unidad de cómputo (2), dicha unidad de cómputo puede generar una orden de activación, para ser enviada al dispositivo de interfaz de usuario (8). Lo anterior, permite avisar al usuario que el estado de madurez de la fruta de la cual se obtiene la imagen es madura. En un ejemplo particular, solo se genera una orden de activación si el dato de estado de maduración de la etapa f) indica que la fruta es madura, en ese caso, por ejemplo, el dispositivo de interfaz de usuario (8) es un dispositivo de interfaz de usuario (8) de luz, el cual se conforma de una bombilla y un controlador, en donde el controlador recibe la orden de activación y genera una señal de control que es enviada a la bombilla para encenderse.

Por otro lado, la unidad de cómputo (2) pueden generar dos órdenes de activación, una orden de activación de maduración y una orden de activación de no maduración, las cuales son enviadas al dispositivo de interfaz de usuario (8) que en este caso está configurado para reproducir la orden que se recibe y mostrar al usuario en cuál de los datos estados se encuentra la fruta.

Por ejemplo, el dispositivo de interfaz de usuario (8) puede ser un dispositivo interfaz de usuario (8) de luz, el cual se conforma de dos bombillas y un controlador, en donde el controlador recibe la orden de activación de maduración y genera una señal de control que se envía a una bombilla, la cual se enciende. Por su lado, cuando el controlador recibe la orden de activación de no maduración genera una señal de control que se envía a la otra bombilla, la cual enciende.

El dispositivo de la presente invención puede contar con un señalador, en donde dicho señalador permite apuntar a la fruta, la cual se va a determinar el estado de maduración. El señalador está configurado para alinearse con el segmento que el dispositivo de adquisición de datos (1) va a obtener, es decir, si el usuario apunta con el señalador una fruta en específico en el árbol y el dispositivo de adquisición de imágenes (1) obtiene la imagen de la fruta señalada por el señalador. Lo anterior permite al usuario escoger cada fruta que quiera

evaluar. Opcionalmente, el señalador se apaga cuando el dispositivo de adquisición de imágenes (1) se disponga a obtener la imagen, esto con el objetivo de no afectar la calidad de la imagen obtenida. En un ejemplo particular, el señalador es un señalador laser.

Opcionalmente, después de obtener el dato de estado de maduración de la etapa f), la unidad de cómputo (2) puede generar una orden activación, para ser enviada al dispositivo de cosecha de frutas. El controlador del dispositivo de cosecha de frutas recibe la orden de activación de cosecha y genera una señal de control que es enviada al actuador del dispositivo de cosecha de frutas, dicho actuador se activa moviendo el elemento de cosecha para cosechar la fruta. El dato de estado de maduración puede ser un dato binario, en donde por ejemplo cuando el dato de estado de maduración es 1 se considera madura la fruta, a la cual fue obtenida la imagen y cuando el dato de estado de maduración es 0 se considera inmadura a la fruta, a la cual fue obtenida la imagen.

Ejemplo

Se diseñó un dispositivo para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, las características del dispositivo son las siguientes:

Para este ejemplo particular, la unidad de cómputo (2) es una Jetson Nano que cuenta con los siguientes módulos:

- la unidad central de procesamiento (4): GPU NVIDIA Maxwell™ architecture with 128 NVIDIA CUDA® cores, CPU Quad-core ARM® Cortex®-A57 MPCore processor
- Memoria temporal (5): 4 GB 64-bit LPDDR4
- Unidad de memoria (3): 16 GB eMMC 5.1 Flash
- Módulo de comunicaciones (6) alámbrico e inalámbrico: compatible con WLAN (Externo), Bluetooth® (Externo), y red Ethernet (integrado).

La unidad de cómputo (2) que se conecta con un módulo de alimentación (7) que es un batería de litio de 10000 mAh, se aloja dentro de una primera carcasa (12) que tiene una tapa (11).

Por su lado, el dispositivo de adquisición de imágenes (1) es una Raspberry pi camera conectada a la unidad de cómputo (2), con un sensor Sony IMX219.

Además, el dispositivo de la presente invención cuenta con un dispositivo de distanciamiento (14) que es un Parallax 15-122 cm Láser Rangefinder y con un dispositivo interfaz de usuario (8) de luz que comprende dos bombillas. Por otro lado, el dispositivo de la presente invención cuenta con un señalador laser.

Por otro lado, el dispositivo de adquisición de imágenes (1), el dispositivo interfaz de usuario (8) y el dispositivo de distanciamiento (14) se disponen en una segunda carcasa (12), la cual cuenta con un sistema de agarre configurado para ajustarse al brazo del usuario.

El usuario puede poner la segunda carcasa (14) en su brazo y la primera carcasa (12) la puede llevar en una maleta que cargaba el usuario alrededor de la cadera, como se observa en las FIGS. 2 y 3. En este caso, la unidad de cómputo (2) se conecta al dispositivo de adquisición de imágenes (1) por medio de un cable que se conecta los módulos de comunicaciones de cada elemento.

En este caso se realizó una prueba en donde el usuario se acercó a un árbol de aguacates y seleccionó uno en el árbol señalándolo con el dispositivo de distanciamiento (14), con el cual se determinó la distancia correcta entre el usuario y la fruta y se obtuvo una imagen, la cual estaba en un formato tiff no comprimido. Esta imagen se envió a la unidad de cómputo (2) quien realizó el procesamiento de la imagen y generó una orden de activación que fue enviada al dispositivo interfaz de usuario (8) de luz, el cual encendió la bombilla, indicando así que la fruta seleccionada se encontraba madura.

EJEMPLO 2

El sistema del ejemplo 1 ejecuta el siguiente método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen. En primer lugar, se hace ingreso en la unidad de cómputo (2) los datos de referencia del estado de madurez y unos descriptores de textura, que se obtuvieron por medio de un proceso de selección que tuvo en cuenta una muestra de imágenes de aguacates tomada previa a la prueba realizada. Los descriptores de textura y sus respectivos métodos de cálculo son los mostrados en la siguiente tabla:

Método	Descriptor de textura
patrón binario local	Media
Filtro Eigen	Entropía
Descomposición Wavelet	Entropía
la técnica del espectro de poder	Skewness
histogramas de suma y diferencia	Homogeneidad

Los datos de referencias del estado de madurez corresponden a los valores del cálculo de estos descriptores de textura, donde se considera que la fruta está madura. Una vez se almacenan los descriptores de texturas y los datos de referencias del estado de madurez, se realizó una prueba en donde el usuario se acercó a un árbol de aguacates y seleccionó uno en el árbol señalándolo con el dispositivo de distanciamiento (14), con el cual se determinó que la distancia entre el usuario y la fruta era de 0.5 metros y se obtuvo una imagen, la cual estaba

en un formato tiff no comprimido. Esta imagen fue procesada aplicando el proceso de CLAHE mediante la unidad central de procesamiento (4) de la unidad de cómputo (2) y se guardó en una memoria temporal (5).

Luego, la imagen procesada fue transformada a un espacio de color HSV mediante un proceso de transformación que lleva a cabo la unidad central de procesamiento (4) de la unidad de cómputo (2), y luego se aplicaron los descriptores de texturas seleccionados en el canal S del espacio de color HSV, para obtener un arreglo de datos de textura, el cual es procesado por un método de clasificación que es una máquina de soporte vectorial (SVM) que tiene en cuenta los datos de textura y los datos de referencias del estado de madurez para obtener un dato de estado de madurez. Una vez se obtuvo el dato de estado de madurez, la unidad de cómputo (2) genera una orden de activación que fue enviada al controlador del dispositivo de interfaz de usuario (8) de luz, el cual encendió la bombilla, indicando así que la fruta seleccionada se encontraba madura.

Luego, se desprendió la fruta y se realizaron ensayos destructivos para determinar su porcentaje de materia seca, que para esta fruta fue de 27.8%. Lo anterior, verifica que con el dispositivo y el método anterior efectivamente se determina el estado de madurez de una fruta sin tener contacto con esta, solo con el procesamiento de su imagen.

EJEMPLO 3

Se hizo un proceso de selección para obtener los datos de referencia del estado de madurez y los descriptores de textura usados en el ejemplo 2, en el cual se obtuvieron varias imágenes en total 86 fotos de aguacates, que tenían un porcentaje de materia seca en un rango entre 9.75% y 47.26%, de los cuales 59 estaban inmaduros y 27 estaban maduros, en donde los aguacates maduros superaban los 23,5% de materia seca.

Las imágenes se obtuvieron y cada imagen se dividió en 9 segmentos para seleccionar el segmento central con un tamaño de 600 x 600 píxeles, cada segmento fue procesado aplicando el proceso de CLAHE, para luego, transformar los segmentos procesados de RGB a HSV.

En este caso se partió de 100 descriptores de texturas con sus respectivos métodos de textura, los cuales son los siguientes:

Método	Descriptor de textura
histogramas de suma y diferencia	Energía, entropía, contraste, homogeneidad y correlación.
matriz de co-ocurrencia	Energía, entropía, contraste, homogeneidad y correlación.

matriz de longitud de corrida de nivel de gris (GLRLM)	Énfasis a corto plazo (SRE), Énfasis a largo plazo (LRE), No uniformidad de nivel de grises (GLN), no uniformidad de longitud de ejecución (RLN), Porcentaje de ejecución (RP), Énfasis de ejecución de bajo nivel de grises (LGRE), énfasis de ejecución de nivel de gris alto (HGRE), Énfasis de bajo nivel de grises de corto plazo (SRLGE), corto plazo Énfasis de nivel de gris alto (SRHGE), gris bajo de largo plazo Nivel de énfasis (LRLGE) y nivel de grises alto a largo plazo Énfasis (LRHGE)
patrón binario local (LBP)	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
medidas de textura de leyes	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
filtro propio	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
filtro de gabor	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
la pirámide gaussiana	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
la pirámide orientable	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
descomposición de ondículas	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
la técnica del espectro de poder	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
la distribución de Wigner	Media, mediana, desviación estándar, oblicuidad, curtosis y entropía.
modelos autorregresivos	Ocho coeficientes
campo aleatorio de markov gaussiano	Siete coeficientes

Se determinaron 100 descriptores en cada canal HSV de cada segmento aplicando los métodos para determinar descriptores de textura respectivos, para obtener un arreglo de datos de referencia de estado de madurez, con el cual se obtuvieron los datos descriptores de textura y los datos de referencias usados en el ejemplo 2, por medio de un método de selección a partir del arreglo de datos de referencia del estado de madurez y de la clasificación de las imágenes entre madura e inmadura.

En donde además en el proceso de selección se tuvieron en cuenta unos criterios de selección como que el descriptor de textura se seleccionaba solo si tiene un valor de probabilidad menor que 0.01. En segundo lugar, con los descriptores de textura seleccionados se calculó la correlación uno a uno y seleccionamos solo los que tenían un R cuadrado inferior a 0,5.

Finalmente, entrenamos una máquina de soporte vectorial con el arreglo de datos de referencias del estado de madurez y obtuvimos una precisión de clasificación en validación cruzada de 10 grupos, luego seleccionamos los vectores de descriptores de textura con la mayor precisión de clasificación cuando son usados por una máquina de soporte vectorial entrenada.

Es importante resaltar que se realizaron pruebas aplicando CLAHE y otras sin aplicar CLAHE, del mismo modo, se hicieron pruebas aplicando los descriptores de textura solo a un canal del espacio de color HSV y otras pruebas aplicando los descriptores de textura a todos los canales del espacio de color HSV. El tamaño final de los vectores estuvo entre 5 a 32 descriptores de textura.

Se demostró que en general se logró una mejor efectividad usando el canal de saturación (S) y además aplicando CLAHE en donde la efectividad fue 96,42%, en comparación que cuando solo uso el canal de saturación (S) sin aplicar CLAHE donde la efectividad fue 96,26%.

Además, también se observó que la mayor efectividad se obtuvo usando los tres canales del espacio de color HSV y, además, usando CLAHE donde se obtuvo una efectividad del 98,02%, en comparación cuando se usaron los tres canales de espacio de color HSV sin usar CLAHE donde se obtuvo una efectividad del 96,26%.

Glosario:

Madurez Fisiológica: refiere a la etapa del desarrollo de la fruta u hortaliza en que se ha producido el crecimiento y maduración requeridos para que al ser cosechados estas lleguen a madurez de consumo.

Materia Seca: Es la parte que resta de una fruta tras extraer toda el agua posible. El peso obtenido después de la desecación, y calculado su porcentaje, representa el extracto seco.

Índice de cosecha aguacate: Contenido de materia seca de la fruta en el cual alcanza su madurez fisiológica

Descriptor de textura: Representa de forma numérica las características de una textura en una imagen.

Resolución espacial de una imagen: Es una indicación del tamaño del pixel expresada en términos de dimensiones sobre el terreno.

Método de textura: es un algoritmo que determina las relaciones entre los pixeles de una imagen (textura), en donde el algoritmo obtiene como resultados descriptores de texturas.

Imagen: matriz de datos, en el que cada dato es un pixel

Textura: relación de cada pixel con sus vecinos.

Filtros de distorsión: son filtros que se aplican a una imagen para transformar dicha imagen, deformándola, torciéndola o tirando de ella en diferentes direcciones.

Se debe entender que la presente invención no se halla limitada a las modalidades descritas e ilustradas, pues como será evidente para una persona versada en el arte, existen variaciones y modificaciones posibles que no se apartan del espíritu de la invención, definido por las siguientes reivindicaciones

REIVINDICACIONES

1. Un método para determinar un dato del estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende las siguientes etapas:
 - a) ingresar al menos un dato descriptor de textura y unos datos de referencia del estado de madurez en una unidad de memoria de una unidad de cómputo;
 - b) obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una porción de la fruta por medio de un dispositivo de adquisición de imágenes;
 - c) procesar la imagen obtenida en el paso (b), aplicando un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante la unidad de cómputo;
 - d) transformar la imagen procesada del paso (c) a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación en la unidad de cómputo;
 - e) obtener al menos un dato de textura con la unidad de cómputo aplicando un método de textura de acuerdo con el dato descriptor de textura ingresado en el paso (a) en al menos un canal de color Matiz (H), Saturación (S) o Valor (V) del espacio de color HSV de la imagen obtenida en la etapa (d); y
 - f) obtener un dato de estado de maduración mediante un método de clasificación que toma como entrada los datos de textura obtenidos en el paso (e) y los datos de referencia del estado de madurez en la etapa (a).

2. El método de acuerdo con la Reivindicación 1, que además comprende entre la etapa (b) y la etapa (c) una etapa de determinar con la unidad de cómputo si la imagen obtenida en la etapa (b) corresponde a una fruta usando un método de procesamiento de imagen configurado para reconocer frutas, en donde en caso que se determine que la imagen sea una fruta se continúa con la etapa (d) y en caso contrario, la unidad de cómputo genera un dato de alerta.

3. El método de acuerdo con la Reivindicación 1, que además comprende entre la etapa (b) y la etapa (c) una etapa de determinar si la imagen obtenida en la etapa (b) tiene una distorsión menor del 5%, la distorsión de la imagen se determina usando un método de procesamiento de imagen configurado para determinar calidad de imagen, en caso que la distorsión de la imagen sea de menos del 5% se continúa con la etapa (d) y en caso contrario, la unidad de cómputo genera un dato de alerta.

4. El método de acuerdo con la Reivindicación 1, en donde el descriptor de textura y los datos de referencia del estado de madurez ingresado etapa (a), se obtienen al ejecutar en la unidad de cómputo las siguientes sub-etapas:
 - a1) obtener un conjunto de imágenes en un espacio de color Rojo, Verde, Azul (RGB) de un conjunto de frutas por medio de un dispositivo de adquisición de imágenes;
 - a2) obtener de cada fruta del conjunto de frutas un dato de maduración correspondiente a una característica de maduración de la fruta;

a3) asignar a cada imagen obtenida en la etapa a1) el dato de maduración correspondiente a una característica de maduración obtenido en la etapa a2);

a4) clasificar las imágenes de las frutas de acuerdo al dato de maduración asignado y almacenarlas en la unidad de memoria;

a5) procesar las imágenes RGB aplicando un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) mediante la unidad de cómputo;

a6) transformar las imágenes procesada a un espacio de color HSV mediante un proceso de transformación;

a7) ingresar un conjunto de métodos de textura y aplicar cada uno de los métodos de textura de textura ingresados, en los canales de la imagen obtenida en la etapa a6) para obtener un arreglo de datos de referencia del estado de madurez por medio de la unidad de cómputo; y

a8) obtener al menos dato un descriptor de textura y unos datos de referencia del estado de madurez por medio de un método de selección a partir del arreglo de datos de referencia del estado de madurez y de la clasificación de las imágenes de la etapa a4).

5. El método de acuerdo con la Reivindicación 4, en donde en la subetapa a2) la característica de maduración es el porcentaje de materia seca de la fruta.

6. El método de acuerdo con la Reivindicación 4, en donde el método de selección tiene en cuenta unos criterios de selección, los cuales se seleccionan del grupo conformado por un valor de probabilidad (P) de un análisis de varianza (ANOVA), correlación específica entre descriptores, costo computacional, eficacia de predicción en validación cruzada, zona climática y combinaciones de estos.

7. El método de acuerdo con la Reivindicación 4, en donde el criterio de selección es un valor de probabilidad (P) de un análisis de varianza (ANOVA), en donde dicho P es menor que 0.01.

8. El método de acuerdo con la Reivindicación 4, en donde el método de selección es una máquina de soporte vectorial (SVM, por sus siglas en inglés) para clasificación binaria.

9. El método de acuerdo con la Reivindicación 1, en donde la etapa c) tiene las siguientes subetapas:

c1) transformar la imagen a un espacio de color l^*a^*b mediante un proceso de transformación en la unidad de cómputo;

c2) escalar unos valores a unos rangos esperados para la Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE);

c3) aplicar una Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) en el canal l y escalar el resultado para volver al rango utilizado por el espacio de color l^*a^*b ;

c4) transformar la imagen resultante nuevamente en el espacio de color RGB.

10. El método de acuerdo con la Reivindicación 1, en donde en la etapa f) el método de clasificación es una máquina de soporte vectorial (SVM, por sus siglas en inglés) para clasificación binaria.

11. Un dispositivo para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, que comprende:

- un dispositivo de adquisición de imágenes, dicho dispositivo de adquisición de imágenes configurado para obtener una imagen en un espacio de color Rojo, Verde, Azul (RGB) de una fruta;
- una unidad de cómputo conectado al dispositivo de adquisición de imágenes;

en donde la unidad de cómputo está configurada para:

- ingresar al menos un dato descriptor de textura de frutas y unos datos de referencia del estado de madurez en una unidad de memoria de la unidad de cómputo;
- procesar la imagen en el espacio RGB aplicando una Ecuilibración de Histograma Adaptativo Limitado por Contraste (CLAHE);
- transformar la imagen procesada a un espacio de color Matiz, Saturación, Valor (HSV) mediante un proceso de transformación;
- obtener unos datos de textura por medio de la unidad de cómputo aplicando un método s de textura de acuerdo con el dato descriptor de textura ingresado, en al menos uno de los canales de la imagen obtenida; y
- obtener un dato de estado de maduración mediante un método de clasificación, el cual tiene en cuenta los datos de textura obtenidos y los datos de referencia del estado de madurez ingresados.

12. El dispositivo de acuerdo con la Reivindicación 11, en donde el dispositivo de adquisición de imágenes cuenta con un dispositivo de distanciamiento, el cual está configurado para medir la distancia entre el dispositivo de adquisición de imágenes y la fruta; y enviar una señal de control al dispositivo de adquisición de imágenes para que obtenga la imagen de acuerdo con una condición de distanciamiento predefinida.

13. El dispositivo de acuerdo con la Reivindicación 11, en donde el dispositivo de adquisición de imágenes cuenta con un dispositivo de autoenfoco.

14. El dispositivo de acuerdo con la Reivindicación 11, que comprende además un dispositivo interfaz de usuario de luz configurado para encenderse al recibir una orden de activación, en donde la unidad de cómputo está configura para generar la orden de activación cuando obtiene el dato de estado de maduración.

15. El dispositivo de acuerdo con la Reivindicación 11, que comprende además un módulo de alimentación, al cual se conecta la unidad de cómputo y el dispositivo de adquisición de imágenes.
16. El dispositivo de acuerdo con la Reivindicación 11, en donde la unidad de cómputo se conecta con un módulo de comunicaciones.
17. El dispositivo de acuerdo con la Reivindicación 16, en donde la unidad de cómputo se conecta a un dispositivo de cómputo externo mediante el módulo de comunicaciones.
18. El dispositivo de acuerdo con la Reivindicación 16, en donde la unidad de cómputo se conecta a un servidor mediante el módulo de comunicaciones.

RESUMEN

La presente invención se refiere un dispositivo y método para determinar un dato de estado de madurez fisiológica de una fruta a partir de descriptores de textura de su imagen, lo anterior sin tener que estar en contacto directo con la fruta y sin tener ningún tipo de ambiente controlado en contacto con la fruta. Particularmente, la presente invención obtiene una imagen de una fruta en un espacio de color Rojo, Verde, Azul (RGB), la cual procesa con un proceso de Ecuilización de Histograma Adaptativo Limitado por Contraste (CLAHE) y luego la transforma al espacio de color Matiz, Saturación, Valor (HSV). Luego, de la imagen en un espacio de color (HSV) se obtienen unos datos de textura a partir de unos descriptores de textura, dichos datos de texturas son clasificados por medio de un método de clasificación, que puede ser una máquina de soporte vectorial (SVM) para determinar si la fruta está madura.

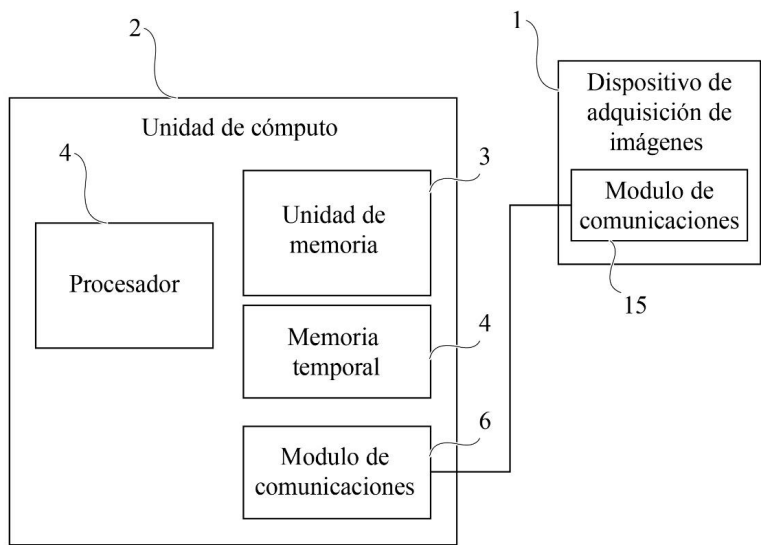


FIG. 1




FIG. 2


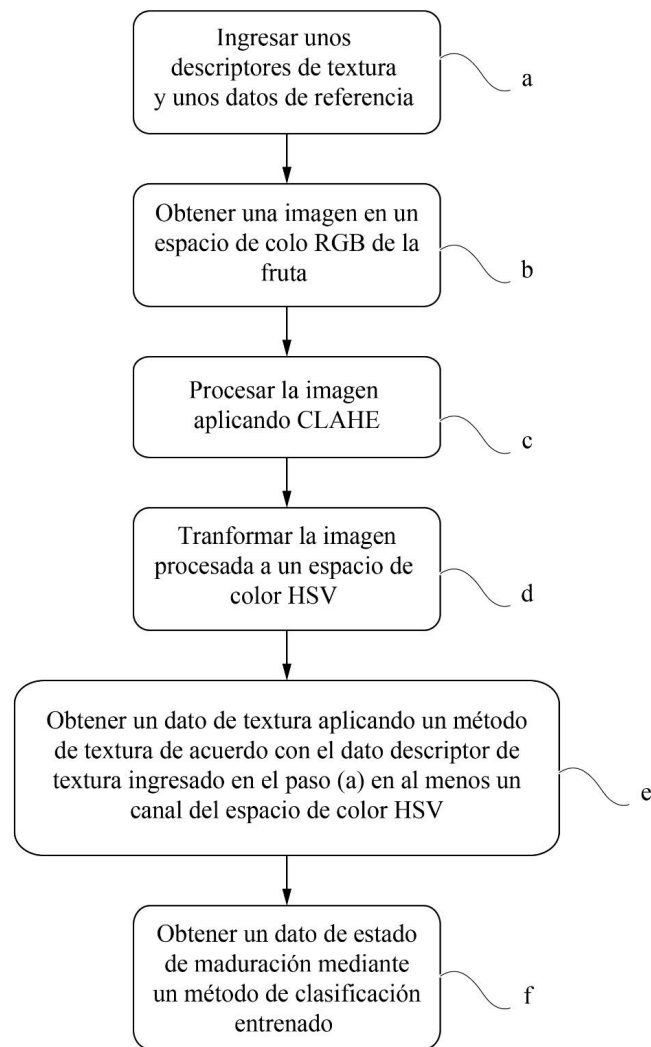


FIG. 3

**FIG. 4**

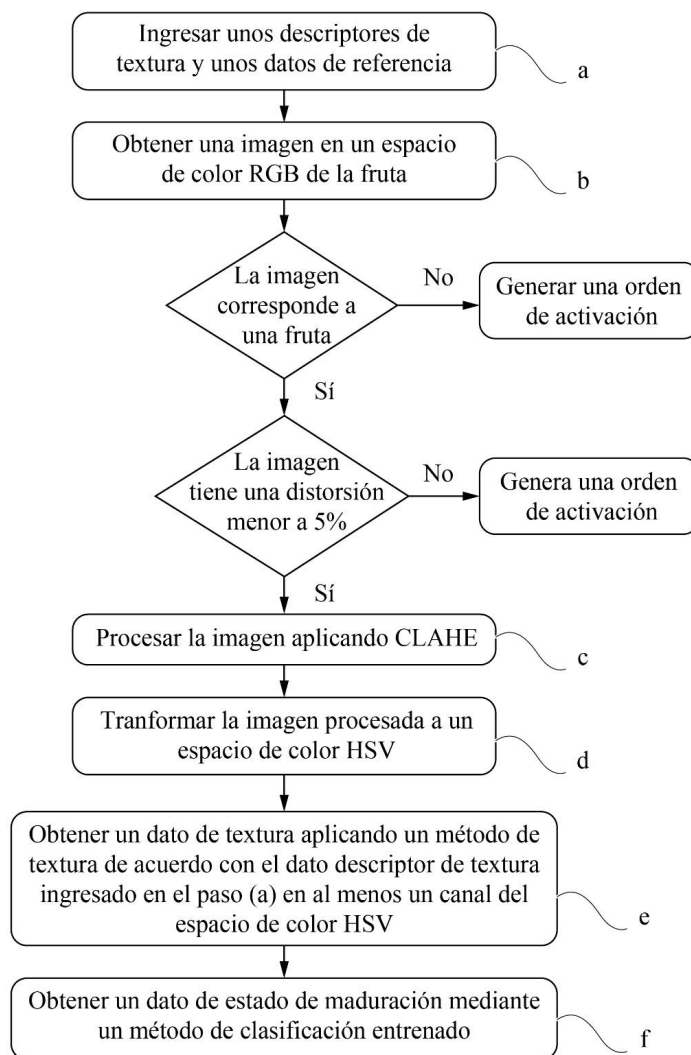


FIG. 5

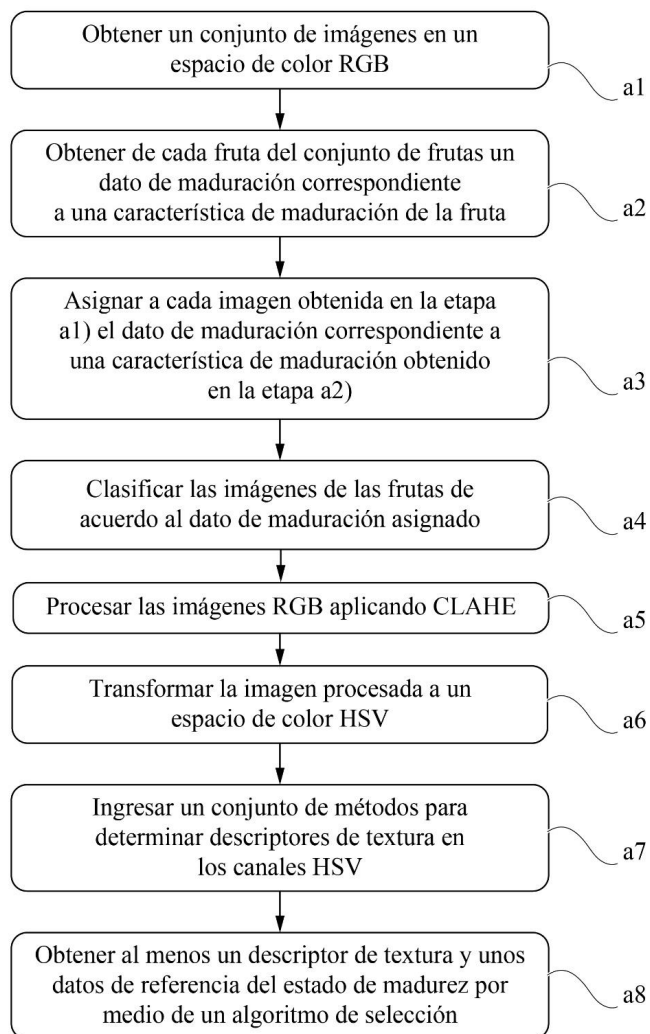


FIG. 6

Anexo B: Artículo 1

Research Article



Received: 10 May 2020

Revised: 19 July 2020

Accepted article published: 31 July 2020

Published online in Wiley Online Library:

(wileyonlinelibrary.com) DOI 10.1002/jsfa.10697

Prediction of dry matter content of recently harvested 'Hass' avocado fruits using hyperspectral imaging

Jhon Jairo Vega Díaz,^{a*}  Angélica Piedad Sandoval Aldana^b  and Deici Viviana Reina Zuluaga^b 

Abstract

BACKGROUND: 'Hass' avocado consumption is increasing due to its organoleptic properties, so it is necessary to develop new technologies to guarantee export quality. Avocado fruits do not ripen on the tree, and the visual classification of its maturity is not accurate. The most commonly used fruit maturity indicator is the percentage of dry matter (DM). The aim of this research was to investigate a non-destructive method with hyperspectral images to predict the percentage of DM of fruits across the spectral range of 400–1000 nm.

RESULTS: No correlation between fruit weight and color with the percentage of DM was found in the study area. Cross-validation efficiency of different data sources, including the spectrum extraction zone (the center, a line from the peduncle to the base, and the whole fruit) and the average of one or two fruit faces, was compared. Four linear regression models were compared. Data of the whole fruit and average of both sides per fruit using a support vector machine regression were selected for the prediction test. Following the cross-validation concept, five sets of calibration and test data were selected and optimized for calibration. The best test prediction set comprised an $R^2 = 0.9$, a root-mean-square error of 2.6 g kg^{-1} DM, a Pearson correlation of 0.95, and a ratio of prediction to deviation of 3.2.

CONCLUSIONS: The results of the study indicate that hyperspectral images allow classifying export fruits and making harvesting decisions.

© 2020 Society of Chemical Industry

Keywords: avocado 'Hass'; dry matter; hyperspectral image; support vector machine regression

INTRODUCTION

Food quality assurance is fundamental in the food industry. In this sector, the consumption of avocado (*Persea americana* Mill) has increased owing to its nutritional value. In 2018, 72.7% of the global avocado production was concentrated in the Americas, with the leading producer being Mexico. Colombia, comparatively, is the fifth largest producer,¹ with the main production regions being Antioquia, Caldas, and Tolima.² This crop has an excellent reputation in international markets and meets high-quality requirements.³ The most commercialized cultivar worldwide is 'Hass'.⁴

In this sense, it is necessary to select fruits of a specific maturity range to achieve export requirements.⁴ As avocado is a climacteric fruit, it does not ripen on the tree;⁵ therefore, it must be harvested after reaching its physiological maturity stage established through the harvest index. At this stage, the fruit completes its edible flavor and firmness.⁶ If the fruit is picked before reaching the harvest index, it suffers undesirable changes in its physical and chemical characteristics.⁷ Some of these changes include shelf life reduction, pink discoloration, greenish spots, seed adhesion to the mesocarp, fibrous vascular tissue, bruised mesocarp color,⁸ sharp or 'herbaceous' flavor, and affectability by microorganisms. Further, physiological maturity heterogeneity of the fruit

leads to shelf life variability, creating the so-called 'chessboard'.⁹ This situation is an obstacle when fruits arrive at the destination port because the fruit is rejected if the physiological maturity level required is not met.

The most important harvest index indicator is the oil content of the fruit. The optimal postharvest process starts when the fruit contains an adequate oil level. However, the determination of this feature is expensive; thus, the dry matter (DM) content is currently used as a harvest parameter due to its linear correlation with oil content.¹⁰ Although the DM content may be one of the best indicators of postharvest quality, pre-harvest conditions are also an influence factor.^{11,12} In Colombia, studies have shown that the oil content must be higher than 11.2 g kg^{-1} , and the optimum fruit DM content must be 23.5 g kg^{-1} .¹³

* Correspondence to: JJ Vega Díaz, Universidad Antonio Nariño, Colombia. E-mail: jvega66@uan.edu.co

a Doctorado en ciencia aplicada, Universidad Antonio Nariño, Bogotá, Colombia

b Facultad de ingeniería agronómica, Universidad del Tolima, Ibagué, Colombia

Destructive techniques are used for statistical projections; nonetheless, it is necessary to use non-destructive techniques for fruit classification. Accordingly, new tools can be used to measure the internal characteristics of fruits and vegetables.^{14,15} Magwaza and Tesfay documented several non-destructive methods,¹⁰ including those that measure fruit reflectances, such as spectrophotometry, hyperspectral imaging (HSI), and visual image processing, as well as others based on ultrasound and nuclear magnetic resonance imaging.

Moreover, the prediction of the DM content of 'Hass' avocado using a spectrometer on the fruit skin has been reported in several studies.¹⁶⁻²² These studies have used multiple linear regression, principal component regression, and partial least squares regression models. In these, the authors used cross-validation for calibration with R^2 in test values ranging from 0.4²³ to 0.98.²⁰ However, the use of this method to determine the DM content of the avocado fruit requires direct contact with the fruit. Thus, to make predictions in the field and directly on the tree, the use of images is a more efficient technique in operational terms.

HSI has been shown to be an innovative technique for food quality and safety assessment. This technique combines traditional optical spectroscopy and computer display into one system to generate spatial and spectral information of the sample simultaneously. HSI was used successfully in avocado postharvest to model its quality,²⁴⁻²⁶ by measuring changes in fruit color. On the other hand, this technique does not apply to recently harvested fruit as the color does not correlate with DM content.

The use of hyperspectral images as a non-destructive process to establish the DM content of avocado fruits after harvest has been researched by Girod *et al.*,²⁷ who calculated the average fruit spectrum based on hyperspectral images, analyzing the spectral curve with spectrometric methods. These results allowed the generation of a prediction model using a partial least squares regression with cross-validation with an R^2 of 0.94. However, in this

research, only data from 21 fruits collected from the market were used, and these suffer color changes due to their normal ripening process. Accordingly, as recently harvested fruits in Colombia are classified using different ineffective methods, the aim of this study is to develop a non-destructive predictive model of the percentage of DM of recently harvested 'Hass' avocado fruits with hyperspectral images, testing regression models and the support vector machine method previously reported in the literature, currently used for classification.²⁸

MATERIAL AND METHODS

Fruit sample

The municipality of Fresno was selected because it has the largest planted area with 'Hass' avocado in the Tolima region.² The fruit orchard selected is located at the following coordinates: 5° 8' 21.6" N and 75°6' 22.5" W. The selected trees were 5 years old, with a planting distance of 8 m by 8 m, canopy distance of 3-4 m and tree height of 3 m.

The fruits were harvested randomly between December 2018 and January 2020 every month, except between February and May due to flowering pruning. The fruit selected presented an equatorial diameter greater than 5 cm. After picking, the fruit were transported in polyethylene coolers at 10 °C to the Postharvest and Quality Laboratory of Universidad del Tolima (Ibagué, Colombia), where data acquisition and laboratory analyses were performed.

Hyperspectral images

The images were taken with a Pika XC2 hyperspectral camera (Resonon, Bozeman, MT, USA)²⁹ over the spectral range of 400-1000 nm. This camera was designed for outdoor photography, so a controlled lighting space was built.³⁰ This space was a 35 cm × 35 cm cube covered with a Lee quarter white diffusion filter³¹ and illuminated with four 300 W halogen lamps (Fig. 1 (a)). The hyperspectral camera was placed on the upper part of




Figure 1. Image acquisition system. (a) Controlled lighting space. (b) Hyperspectral camera assembly.

the controlled lighting space (Fig. 1(b)), and two hyperspectral images were taken of each fruit, one on each side.

Laboratory data

Fruit weight and color

Fruit weight was measured using a digital scale with a flat plate (EW-N, KERN & SOHN GmbH, Balingen, Germany). Subsequently, color parameters were measured at three random points in the equatorial zone of the fruit using a spectrophotometer (CM-5; Konica Minolta, Tokyo, Japan). The results were expressed on the CIELAB scale (L^* : luminosity or brightness; a^* : greenness or redness; b^* : yellow or blue).

Destructive quantification of DM

The fruit DM of the sample was established using the method described in AOAC 925.45.³² Subsamples of approximately 5 g were dried at 105 °C in a convective oven until reaching a constant weight (24 h). The difference between the initial W_0 and final weights W_1 was used to calculate the percentage of DM employing Eqn (1). The DM content is the arithmetic mean value of at least two subsamples per fruit:

$$DM (\%) = \frac{W_0 - W_1}{W_0} \times 100 \quad (1)$$

Data analysis

Spectral data extraction

The Python v3 software employing the spectral³³ and OpenCV³⁴ libraries was used to obtain the average spectrum. A mask without background or skin damage was applied to create a

segmented hyperspectral image. This mask was created extracting the blue (458.88 nm), green (548.68 nm), red (639.07 nm), and infrared (856.79 nm) bands from the hyperspectral image. Then, the red, green, and blue bands were merged into one RGB image. Subsequently, the normalized difference vegetation index (NDVI) with the red and infrared (Nir) bands was calculated using Eqn (2). The mask used to remove the background³⁵ and the skin damage used the NDVI image as a threshold with values of 0.3 and 0.7 (Fig. 2(a)):

$$NDVI = \frac{Nir - Red}{Nir + Red} \quad (2)$$

Based on the segmented image, three masks were obtained with different fruit areas: the whole fruit, its center, and a line from the peduncle to the base of the fruit (Fig. 2(b)). The average spectrum of each image area was calculated, and an RGB image was generated for visual verification (Fig. 2(c)). Three average spectra were obtained per hyperspectral image cube.

Chemometric analysis

A linear relationship between the reflectance of the object and its internal features³⁶ was established, correlating the spectral curve of the avocado skin with the percentage of DM of the fruit. This procedure was carried out using Matlab R2019b software,³⁷ and the regression summary was performed using the R package mdatools (multivariate data analysis for chemometrics) version 0.10.3.³⁸ The best test model was identified in two steps. First, the best data source and regression method for the calibration model were established; second, a prediction test with the selection was performed.

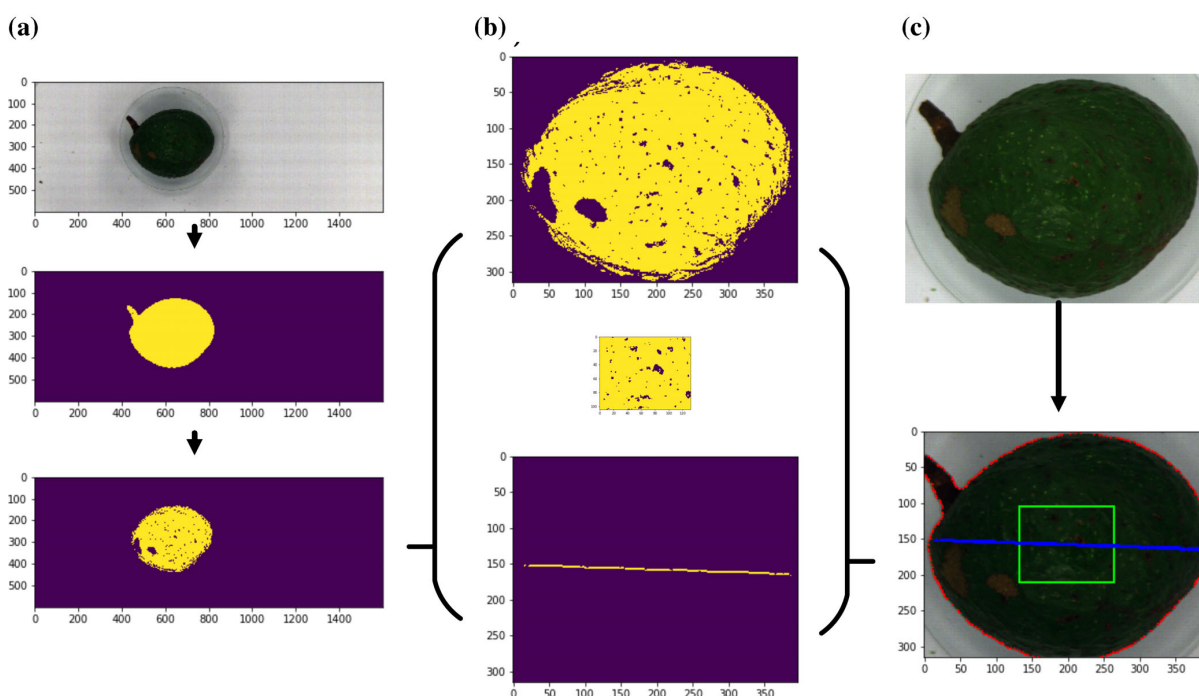


Figure 2. Image segmentation. (a) Fruit and skin damage segmentation from NDVI. (b) Three masks: the whole fruit, the center of the fruit, and a line from the peduncle to the base of the fruit. (c) RGB image of the fruit segmented (red is the whole fruit, green is the center, and blue is a line from the peduncle to the base of the fruit).

Optimized calibration model. Four regression methods (multiple linear, principal component, partial least squares, and support vector machine) with all the samples were tested to establish the best data source and regression method for the calibration model.²⁸ The feature selection for the optimized calibration models involved a selection on a relevant wavelength,³⁹ with the following steps:

- (1) Data preprocessing
- (2) Outlier removal
- (3) Wavelength selection
- (4) Outlier removal with the first optimized model
- (5) New wavelength selection
- (6) Results of the second optimized model

Data preprocessing. The spectrum used the reflectance with the following pretreatments: scatter correction employing the standard normal variate method⁴⁰ and Savitzky–Golay's first derivative,⁴¹ including the following parameters: one degree of the derivative, a spectral window size of 5, and a second-order polynomial.

Cross-validation. The cross-validation method was used to avoid unrealistic calibration models. Calibration models were evaluated in all cases with the tenfold cross-validation method.⁴² The data were divided into nine for training and one for validation. Solely, the latter was used for the model evaluation. The linear relationship between predicted and measured data was represented by the adjusted coefficient of determination R^2 , the root-mean-square error (RMSE),

Pearson's correlation coefficient,⁴³ and the ratio of (standard error of) prediction to (the standard) deviation (RPD)⁴⁴ (Fig. 3).

The final evaluation of the feature selection process was carried out in the second optimized model cross-validation process. As sample distribution between training and validation influences the accuracy metrics, 100 cross-validations were performed. The results are the average of those 100 repetitions; thus, the reported R^2 , RMSE, and RPD are the means of 100 repetitions.

Outlier removal. The model is tested through cross-validation, and data having a predictive value with an error higher than twice the mean squared error are removed. This process is carried out twice, including all the original data.

Wavelength selection. A supervised band selection process with two steps was used: a regression-based method was carried out⁴⁵ and then an incremental searching-based method.⁴⁶ The first method uses an iterative linear model training process that removes the band with the lowest beta coefficient and evaluates it through cross-validation.⁴⁷ Then, the model with the highest R^2 was selected. The second method takes this model and removes the chosen bands one after another and evaluates it through cross-validation. Finally, the model with the highest R^2 and the smallest number of bands was selected.

Selecting the best data source and regression method. A three-way analysis of variance (ANOVA) was used to test the optimized model calibration. This ANOVA uses the 100 repetitions' RMSE of the calibration regression. The use of this test allowed us to obtain the significance between the fruit area,

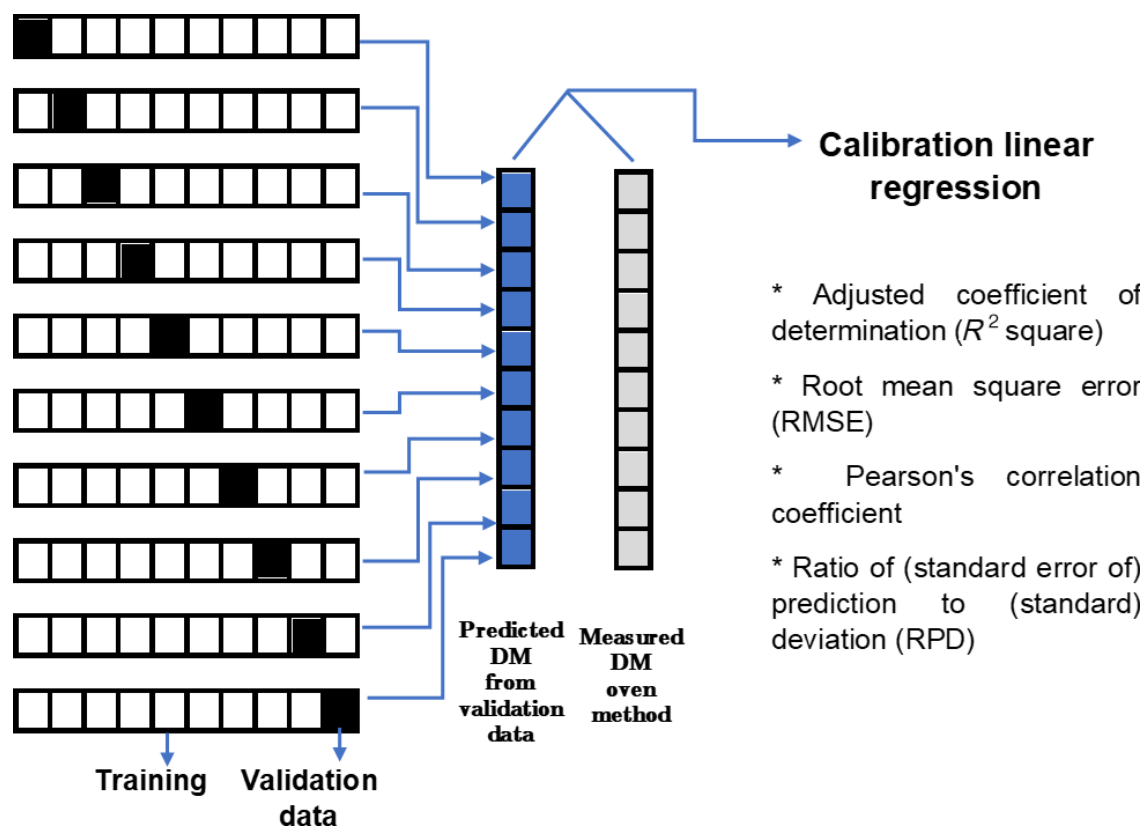


Figure 3. Tenfold cross-validation.

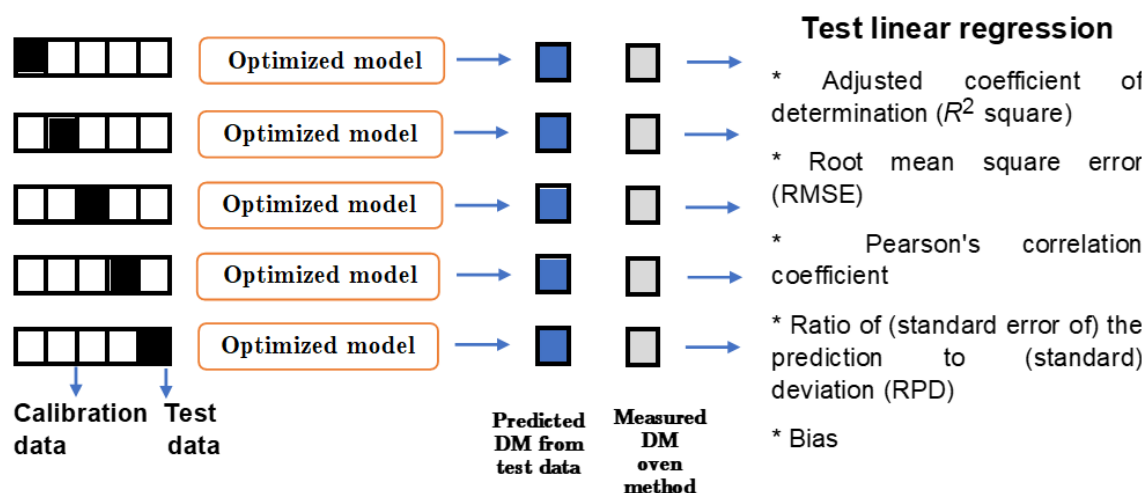


Figure 4. Data sets to carry out a prediction test.

the average spectrum of one or both sides of the fruit, and the regression methods. The best data source and regression method were selected using pairwise comparisons with Tukey's test and establishing a significant individual difference or differences between them.

Prediction test. Data were divided into two groups: 80% were used for calibration, and the remaining 20% were used to test the predictive accuracy of the data source and the selected regression method. Following the cross-validation concept, five data combinations testing all data were evaluated. Figure 4 presents the workflow in three steps. In the first step, data preprocessing and outlier removal processes were carried out. In the second step and for each data set, a wavelength selection process was applied with the calibration data. In the third step, the optimized model is trained with the calibration data and test data are predicted. Prediction accuracy is measured employing R^2 , RMSE, Pearson's correlation coefficient,⁴³ RPD, and bias⁴⁴ (Fig. 4).

RESULTS

This study used the information from 706 fruits; the mean DM content of these samples was $24.8658 \text{ g kg}^{-1}$, with standard deviation 8.3111 g kg^{-1} and minimum and maximum values of 9.76 g kg^{-1} and 47.26 g kg^{-1} respectively. Colombian exporters prefer fruit with a maximum DM content of 30 g kg^{-1} , but with a DM higher than 23 g kg^{-1} .⁶

Fruit weight and its DM content results are shown in Fig. 5. Moreover, fruit color parameters and DM content results are shown in Fig. 6. In these two figures, the fruit color and weight variables have no relationship to the DM content. The R^2 values of DM content versus the other variables are 0.06 for weight, 0.42 for L^* , 0.25 for a^* , and 0.35 for b^* . As a result, the maturity of the fruits from the study area cannot be classified by weight and color parameters.

Six groups of spectra from the same fruits were obtained using the spectrum average of one or both sides of the fruit. Moreover, three regions of interest (ROIs) were employed to select the area of the image from which the data were extracted (the whole fruit, its center, and a line from the peduncle to the base of the fruit).

With each group of spectra, an optimized calibration model with four linear regression methods and the mean of the efficiency metrics of the models in cross-validation of 100 repetitions were obtained.

Table 1 shows that the model with the lowest fit is the one calculated through the multiple linear regression with data of one side of the fruit and extracted from the center of the fruit. The model with the best fit is, in contrast, the one calculated by the support vector machine with data of both sides of the fruit and extracted from the whole fruit. In most cases, the correlation is 0.95, and the RMSE is between 2 and 2.4. However, the efficiency indicators of the method with support vector machine exceed the trend, a result that is confirmed by the RPD value being >4 , which classifies fruits as excellent.⁴⁴

The three-way ANOVA performed (Table 2) showed that there are significant differences between all factors and some interactions between the models. Using Tukey's significant difference criterion at 99% confidence, the first factor, which is the origin of the




Figure 5. Weight versus dry matter content of recently harvested 'Hass' avocado fruits.




Figure 6. Color parameters for recently harvested 'Hass' avocado fruit skin versus dry matter content. (a) L^* coordinate versus dry matter percent; (b) a^* coordinate versus dry matter percentage; (c) b^* coordinate versus dry matter percentage.

data according to the number of sides of the fruit, showed significant differences with less error when using the average of both sides of the fruit. For the second factor, there is a significant difference with less error when using the regression method with the support vector machine. Finally, for the third factor and according to the ROI, there is a significant difference with the central area of the fruit, which presents a higher error than with the other methods. On the contrary, when using the data of the whole fruit, there is less error in this factor. The interactions tested (Table 2) employing Tukey's test at 99% confidence show that the support vector machine with data of both sides of the fruit is the best method.

The spectra source selected for the test is the average spectrum of both sides of the 'Hass' avocado fruit with an ROI in the whole fruit. Figure 7 shows the original spectra selected, where the color of each spectral curve represents its percentage of DM. The crossing of spectral curves represents different DM contents, without including the groups by maturity level.

The selected source was pretreated to obtain the first derivative of the reflectance value and carry out the prediction test. Then, outliers were removed with the support vector machine as a

regression method. In this process, the number of samples was reduced from 706 to 672. Subsequently, five calibration models were optimized, and the prediction efficiency was evaluated with test data. The results are shown in Table 3.

In Table 3, set 1 has the best set of prediction data is the first, and the worst is set 4. The calibration and test samples between the data types are balanced, as shown by the mean and standard deviation of the samples, reflected in the low bias value for the prediction model. The best data sets show that the available information allows projecting a prediction of new fruits with an R^2 under testing of 0.90, a correlation under testing of 0.95, and an RPD under testing of 3.2; that is, these are classified as adequate to be applied in quality control.

The best data sets and the 133 wavelengths selected in the optimization process and their beta coefficients are shown in Fig. 8. In this figure, the model uses data from both the visible and the infrared spectra, and the six wavelengths with the highest absolute beta coefficient are 909.71 nm, 687.16 nm, 717.98 nm, 896.12 nm, 577.86 nm, and 746.17 nm. Thus, the wavelengths that provide more information to the model are among the colors green, red, and infrared, highlighting a higher contribution of the infrared.

Table 1. Optimized calibration models with four regression methods and six spectral groups (average spectrum: 2; ROI: 3) for the skin of recently harvested 'Hass' avocado fruits. The model efficiency metrics are the mean of 100 repetitions of each optimized calibration model

Method	ROI	Average spectrum							
		One side of the avocado fruit				Both sides of the avocado fruit			
		R^2	Pearson	RMSE	RPD	R^2	Pearson	RMSE	RPD
MLR	Whole fruit	0.9105	0.9541	2.3485	3.3423	0.9117	95.4845	2.3418	3.3658
	Line*	0.9098	0.9538	2.3612	3.3291	0.9093	95.3574	2.3650	3.3205
	Center**	0.8977	0.9474	2.4817	3.1269	0.9026	95.0068	2.4468	3.2047
PCR	Whole fruit	0.9195	0.9589	2.2426	3.5252	0.9177	95.7958	2.2516	3.4854
	Line	0.9184	0.9583	2.2539	3.5006	0.9208	95.9580	2.2084	3.5532
	Center	0.9086	0.9532	2.3614	3.3078	0.9218	96.0109	2.2074	3.5762
PLS	Whole fruit	0.9198	0.9590	2.2115	3.5315	0.9160	95.7079	2.2592	3.4503
	Line	0.9178	0.9580	2.2375	3.4877	0.9172	95.7717	2.2421	3.4757
	Center	0.9186	0.9584	2.2293	3.5053	0.9169	95.7546	2.2428	3.4688
SVMR	Whole fruit	0.9302	0.9644	2.0957	3.7859	0.9458	97.2517	1.8528	4.2950
	Line	0.9281	0.9633	2.1240	3.7291	0.9447	97.1961	1.8791	4.2527
	Center	0.9227	0.9605	2.2010	3.5959	0.9399	96.9512	1.9471	4.0809

MLR, multiple linear regression; PCR, principal component regression; PLS, partial least squares regression; ROI, region of interest; RMSE, root mean square error; RPD, residual prediction deviation; SVMR, support vector machine regression.
*A line from the peduncle to the base of the fruit.
** The center of the fruit.

Table 2. Three-way analysis of variance (ANOVA) for the region of interest (ROI), average spectrum origin, and regression methods. The ANOVA data were obtained from the root mean square error values shown in Table 1

Source	Sum squares	df	Mean square	F	Prob > F
ROI	0.0195	2	0.0097	13.7013	0.0058
No. sides	0.0341	1	0.0341	47.8912	0.0005
Method	0.4315	3	0.1438	202.2352	0.0000
ROI × No. sides	0.0036	2	0.0018	2.5025	0.1621
ROI × Method	0.0106	6	0.0018	2.4941	0.1453
No. sides × Method	0.0646	3	0.0215	30.2855	0.0005
Error	0.0043	6	0.0007		
Total	0.5682	23			

df, degrees of freedom.




Figure 7. Average of the original spectra of both sides of recently harvested 'Hass' avocado fruits with the region of interest in the whole fruit. The color of the spectral curve represents the dry matter content of the fruit in percentage.



Table 3. Five optimized calibration and test models. The calibration model efficiency metrics are the mean of 100 repetitions

Set	Type	N	Dry matter samples (g kg ⁻¹)				R ²	Pearson	RMSE	RPD	Bias	No. wav.
			Mean	SD	Min.	Max.						
1	Calibration	538	24.65	8.08	9.76	43.40	0.95	0.97	1.79	4.35		
	Test	134	24.76	8.56	11.40	42.72	0.90	0.95	2.60	3.20	-8.4E-15	133
2	Calibration	537	24.63	8.15	9.76	43.40	0.94	0.97	1.88	4.25		
	Test	135	24.85	8.25	11.52	41.82	0.88	0.94	2.81	2.86	2E-14	171
3	Calibration	537	25.03	8.17	9.76	43.19	0.94	0.97	1.90	4.20		
	Test	135	23.24	8.04	10.72	43.40	0.88	0.94	2.67	2.84	-1.3E-14	203
4	Calibration	538	24.52	8.15	9.76	43.40	0.95	0.98	1.71	4.66		
	Test	134	25.27	8.26	11.60	43.19	0.82	0.91	3.45	2.39	-6.9E-16	175
5	Calibration	538	24.53	8.29	10.72	43.40	0.95	0.97	1.88	4.31		
	Test	134	25.24	7.67	9.76	38.93	0.87	0.94	2.79	2.83	1.6E-15	183

RMSE, root mean square error; RPD, residual prediction deviation; SD, standard deviation; No. wav., number of selected wavelengths.




Figure 8. Wavelengths selected by an optimization process carried out with the support vector machine linear regressor. The spectral curve represents the data after its preprocessing, and the blue line represents the wavelength selected with the respective beta coefficient value. The red circles represent the six wavelengths with the highest absolute beta coefficient.

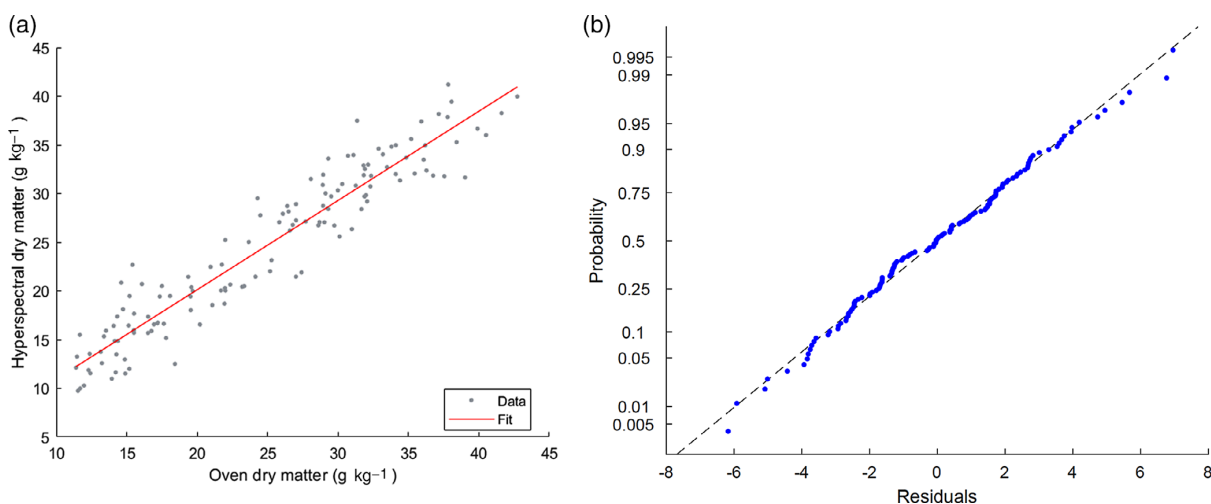


Figure 9. Plots showing the linear regression and normal probability of residuals for the dry matter prediction test of a support vector machine linear regression trained with data of both fruit sides with the region of interest in the whole fruit area versus the dry matter content obtained with the oven method. (a) Linear regression plot. (b) Normal probability plot of residuals.

The DM prediction was made and compared with the values measured by the oven method using the test samples of set 1. The comparison was carried out using simple linear regression. The results of the regression and the normal probability plot of residuals are presented in Fig. 9. The fit equation used was $y = a + bx$, with an intercept a of 1.7769 and a slope b of 0.91716. The error graph shows how the error has a normal distribution, corroborated by a low bias value of -8.4×10^{-15} (Table 3).

DISCUSSION

It is not possible to classify the maturity of 'Hass' avocado fruits in the study area by weight or color. This result is contrary to what Rodriguez *et al.*⁶ and Herrera-González *et al.*⁴⁸ found. In those two studies, the authors show a variation of avocado fruit color according to its maturity; however, fruit quality does not correlate well with skin color,⁴⁹ and the origin of the fruit influences the changes on the fruit skin due to differences in anthocyanin levels.⁵⁰ Therefore, the climatic conditions of the study area influence the visual expression of the fruit skin and its relationship to ripening.

The most efficient optimized calibration model is the one that uses the source data of the whole fruit with the average value of both sides of the fruit employing a support vector machine regressor. The fact that the most efficient data origin is the one that characterizes most of the fruit agrees with the findings reported by Woolf *et al.*⁵¹ against the DM content heterogeneity in avocado. For feature selection, the support vector machine regression method shows a higher predictive efficiency. Thus, this non-parametric method allows optimizing a good model. Nevertheless, there is a high level of difference in the computational cost in comparison with the other regression methods.

The feature selection involved in wavelength choice was the most relevant for the regression method. Nonetheless, the process of selecting bands includes reducing dimensionality and increasing accuracy. The number of wavelengths varied from 42 to 203 when using different data origins and different regressors. The wavelengths selected varied between optimized models and using both visible and infrared information. However, the beta coefficients of the regressions are higher in the green, red, and infrared ranges.

The source data for the calibration model is likely to obtain an $R^2 > 0.94$ and an RPD > 4 ; therefore, these data can be used for calibration. However, the best prediction test shows an $R^2 = 0.9$ and an RPD = 3.2. Hence, the data can predict DM content during quality control,⁴⁴ and it is feasible to classify the fruit in the range of dry matter allowed for export.

CONCLUSIONS

The maturity of the 'Hass' avocado fruits from the municipality of Fresno in the Tolima region cannot be classified by weight and color parameters, probably due to the climatic conditions in the study area.

After evaluating six spectral groups, it can be concluded that it is significantly better to use data from both sides of the fruit, the whole area of the fruit as ROI, and to use the support vector machine method. Following the cross-validation concept, five sets of calibration and test data were selected. Then, five linear regression models were optimized for calibration, and the mean accuracy prediction test between models was 0.9 for R^2 , 2.6 g kg⁻¹ of DM for RMSE, 0.95 for Pearson's correlation, and 3.2 for RPD.

Furthermore, with this accuracy, it is possible to classify export fruits and make harvesting decisions.

The next recommended steps are to test this model with data from other seasons and locations and to make classifications directly on the tree.

ACKNOWLEDGEMENTS

Author contributions

JJ Vega Diaz: conceptualization, methodology, investigation, software, formal analysis, and writing the original draft. AP Sandoval Aldana: conceptualization, methodology, resources, project leader, and writing the original draft. DV Reina Zuluaga: investigation and data acquisition.

This document is the results of the research project funded between the government of Tolima and Universidad del Tolima (agreement no. 2076) entitled 'Knowledge development for the generation of production and post-harvest technologies for "Hass" avocado in the Tolima region'.

REFERENCES

- 1 Food and Agriculture Organization of the United Nations. FAOSTAT. Statistical databases. [Internet]. 2020. Available: <http://www.fao.org/faostat/es/#data/QC> [28 January 2020]
- 2 Ministerio de Agricultura y Desarrollo Rural. Agronet. Estadísticas agropecuarias [Internet]. 2020. Available: <http://www.agronet.gov.co/estadistica/Paginas/default.aspx> [12 August 2020].
- 3 ICONTEC. NTC 5209. Aguacate. Variedades Mejoradas. Especificaciones. Instituto Colombiano de Normas Técnicas y Certificación 2003;26.
- 4 Astudillo-Ordóñez CE and Rodríguez P, Parámetros fisicoquímicos del aguacate *Persea americana* Mill. cv. Hass (Lauraceae) producido en Antioquia (Colombia) para exportación. *Corpoica Cienc y Tecnol Agropecu* **19**:383–392 (2018).
- 5 Estrada B, Alonso J. 2016 Estudios ecofisiológicos en aguacate cv. Hass en diferentes ambientes como alternativa productiva en Colombia. Universidad Nacional; 2016. Available: <http://www.bdigital.unal.edu.co/50844/> [9 May 2017]
- 6 Rodríguez P, Henao JC, Correa G and Aristizabal A, Identification of harvest maturity indicators for 'Hass' avocado adaptable to field conditions. *HortTechnology* **28**:815–821 (2018).
- 7 Santana I, Castelo-Branco VN, Guimarães BM, de Oliveira Silva L, Oliveira Di Sarli Peixoto V, Corrêa Cabral LM *et al.*, Hass avocado (*Persea americana* Mill.) oil enriched in phenolic compounds and tocopherols by expeller-pressing the unpeeled microwave dried fruit. *Food Chem* **286**:354–361 (2019).
- 8 Mazhar M, Joyce D, Hofman P and Vu N, Factors contributing to increased bruise expression in avocado (*Persea americana* M.) cv. 'Hass' fruit. *Postharvest Biol Technol* **143**:58–67 (2018).
- 9 Pedreschi R, Muñoz P, Robledo P, Becerra C, Defilippi BG, van Eekelen H *et al.*, Metabolomics analysis of postharvest ripening heterogeneity of "Hass" avocados. *Postharvest Biol Technol* **92**:172–179 (2014) Available: <http://linkinghub.elsevier.com/retrieve/pii/S092552141400043X> [2 March 2017].
- 10 Magwaza LSS and Tesfay SZZ, A review of destructive and non-destructive methods for determining avocado fruit maturity. *Food Bioprocess Technol* **8**:1995–2011 (2015).
- 11 Hernández I, Fuentealba C, Olaeta JA, Lurie S, Defilippi BG, Campos-Vargas R *et al.*, Factors associated with postharvest ripening heterogeneity of "Hass" avocados (*Persea americana* Mill). *Fruits* **71**:259–268 (2016) Available: <http://www.pubhort.org/fruits/2016/5/fruits160045.htm>.
- 12 Escobar JV, Rodríguez P, Cortes M and Correa G, Influence of dry matter as a harvest index and cold storage time on cv. Hass avocado quality produced in high tropic region. *Inf Tecnol* **30**:199–210 (2019). (in Spanish with English abstract).
- 13 Carvalho CP, Velásquez MA and Van Rooyen Z, Determination of the minimum dry matter index for the optimum harvest of "Hass" avocado fruits in Colombia. *Agron Colomb* **32**:399–406 (2014).

- 14 Arendse E, Fawole OA, Magwaza LS and Opara UL, Non-destructive prediction of internal and external quality attributes of fruit with thick rind: a review. *J Food Eng* **217**:11–23 (2018).
- 15 Walsh KB, McGlone VA and Han DH, The uses of near infra-red spectroscopy in postharvest decision support: a review. *Postharvest Biol Technol* **163**:111–139 (2020).
- 16 Wedding BB, Wright C, Grauf S, White RD and Gadek PA, Near infrared spectroscopy as a rapid non-invasive tool for agricultural and industrial process management with special reference to avocado and sandalwood industries. *Desalin Water Treat* **32**:365–372 (2011) Available: <http://www.tandfonline.com/doi/abs/10.5004/dwt.2011.2723>.
- 17 Walsh KB, Golic M and Greensill CV, Sorting of fruit using near infrared spectroscopy: application to a range of fruit and vegetables for soluble solids and dry matter content. *J Near Infrared Spectrosc* **12**: 141–148 (2004).
- 18 Olarewaju OO, Bertling I and Magwaza LS, Non-destructive evaluation of avocado fruit maturity using near infrared spectroscopy and PLS regression models. *Sci Hortic* **199**:229–236 (2016).
- 19 Clark CJ, McGlone VA, Requejo C, White A and Woolf AB, Dry matter determination in 'Hass' avocado by NIR spectroscopy. *Postharvest Biol Technol* **29**:301–308 (2003).
- 20 Ncama K, Magwaza LS, Poblete-Echeverría CA, Nieuwoudt HH, Tesfay SZ and Mditshwa A, On-tree indexing of 'Hass' avocado fruit by non-destructive assessment of pulp dry matter and oil content. *Biosyst Eng* **174**:41–49 (2018).
- 21 Subedi PP and Walsh KB, Assessment of avocado fruit dry matter content using portable near infrared spectroscopy: method and instrumentation optimisation. *Postharvest Biol Technol* **161**:111078 (2020).
- 22 Wedding BB, Wright C, Grauf S, White RD, Tilse B and Gadek P, Effects of seasonal variability on FT-NIR prediction of dry matter content for whole Hass avocado fruit. *Postharvest Biol Technol* **75**:9–16 (2013).
- 23 Blakey RJ, Evaluation of avocado fruit maturity with a portable near-infrared spectrometer. *Postharvest Biol Technol* **121**:101–105 (2016).
- 24 Karimi Y, Maftoonazad N, Ramaswamy HS, Prasher SO and Marcotte M, Application of hyperspectral technique for color classification avocados subjected to different treatments. *Food Bioprocess Technol* **5**: 252–264 (2012).
- 25 Maftoonazad N, Karimi Y, Ramaswamy HS and Prasher SO, Artificial neural network modeling of hyperspectral radiometric data for quality changes associated with avocados during storage. *J Food Process Preserv* **35**:432–446 (2011).
- 26 Pinto J, Rueda-Chacón H and Arguello H, Clasificación de aguacate Hass (*Persea americana* Mill) en términos de su madurez por medio de imágenes hiperespectrales. *Tecnológicas* **22**:109–128 (2019) Available: <http://hdl.handle.net/20.500.12622/1087>.
- 27 Girod DM, Landry J-A, Doyon G and Osuna Garcia JA, Predicting maturity of Hass avocado using hyperspectral imagery. *Caribb Food Crop Soc* **44**:144 (2008–154). Available: https://www.researchgate.net/publication/280318663_Evaluating_Hass_Avocado_Maturity_Using_Hyperspectral_Imaging.
- 28 Torres I and Amigo JM, An overview of regression methods in hyperspectral and multispectral imaging. *Data Handl Sci Technol* **32**: 205–230 (2020).
- 29 Resonon. Resonon, Pika XC2 [Internet]. 2020. Available: <https://resonon.com/Pika-XC2> [16 February 2020]
- 30 Girod D, *Détermination de la Maturité des Avocats Hass par Imagerie Hyperspectrale*. École de technologie supérieure, Montréal, QC, p. 172 (2008) Available: http://espace.etsmtl.ca/137/1/GIROD_Denis.pdf.
- 31 Lee Filters. Technical Filters. 251 Quarter White Diffusion [Internet]. 2020. Available: <http://www.leafilters.com/lighting/colour-details.html#251> [16 February 2020]
- 32 AOAC International, in *Official Methods of Analysis of AOAC International*, 16th edn, ed. by Cunniff P. Association of Official Analytical Chemist, Washington, DC (1995) Available: <https://www.worldcat.org/title/official-methods-of-analysis-of-aoac-international/oclc/421897987> [27 March 2019].
- 33 Cokelaer T and Hasch J, 'Spectrum': spectral analysis in Python. *J Open Source Softw* [Internet] **2**:348 (2017). <https://doi.org/10.21105/joss.00348>.
- 34 Garrido G and Joshi P, *OpenCV 3.x with Python by Example: Make the Most of OpenCV and Python to Build Applications for Object Recognition and Augmented Reality*, 2nd edn. Packt Publishing, Birmingham, UK (2018).
- 35 Pu Y-Y, Feng Y-Z and Sun D-W, Recent progress of hyperspectral imaging on quality and safety inspection of fruits and vegetables: a review. *Compr Rev Food Sci Food Saf* **14**:176–188 (2015).
- 36 Ma J, Sun D-W, Pu H, Cheng J-H and Wei Q, Advanced techniques for hyperspectral imaging in the food industry: principles and recent applications. *Annu Rev Food Sci Technol* **10**:197–220 (2019).
- 37 MathWorks, *MATLAB Programming Fundamentals*. The MathWorks Inc., Natick, MA (2019). Available: https://la.mathworks.com/help/pdf_doc/matlab/matlab_prog.pdf.
- 38 Kucheryavskiy S, mdatools – R package for chemometrics. *Chemom Intel Lab Syst* **198**:103937 (2020).
- 39 Jia B, Wang W, Ni X, Lawrence KC, Zhuang H, Yoon S-C *et al.*, Essential processing methods of hyperspectral images of agricultural and food products. *Chemom Intel Lab Syst* **198**:103936 (2020).
- 40 Amigo JM and Santos C, Preprocessing of hyperspectral and multispectral images. *Data Handl Sci Technol* **32**:37–53 (2020).
- 41 Ravikanth L, Jayas DS, White NDG, Fields PG and Sun D-W, Extraction of spectral information from hyperspectral data and application of hyperspectral imaging for food and agricultural products. *Food Bioprocess Technol* **10**:1–33 (2017).
- 42 Westad F and Marini F, Validation of chemometric models – a tutorial. *Anal Chim Acta* **893**:14–24 (2015).
- 43 Zou KH, Tuncali K and Silverman SG, Correlation and simple linear regression. *Radiology* **227**:617–622 (2003).
- 44 Williams P, Antoniszyn J and Marley M, *Near-Infrared Technology: Getting the Best Out of Light*, 1st edn. African Sun Media, Stellenbosch, South Africa, p. 311 (2019). <https://africansunmedia.store.it.si/za/book/near-infrared-technology/830503>.
- 45 Maier A and Rodriguez-Salas D, Fast and robust selection of highly-correlated features in regression problems, in *Proceedings of the Fifteenth IAPR International Conference on Machine Vision Applications*. MVA Organization, Kanagawa, Japan, pp. 482–485 (2017).
- 46 Sun W and Du Q, Hyperspectral band selection: a review. *IEEE Geosci Remote Sens Mag* **7**:118–139 (2019).
- 47 Guyon I and Elisseeff A, An introduction to variable and feature selection. *J Mach Learn Res* **3**:1157–1182 (2003) Available: <http://dl.acm.org/citation.cfm?id=944919.944968>.
- 48 Herrera-González JA, Salazar-García S, Martínez-Flores HE and Ruiz-García JE, Indicadores preliminares de madurez fisiológica y comportamiento postcosecha del fruto de aguacate Méndez [Preliminary signs of physiological maturity and postharvest performance of Méndez avocado fruit]. *Rev Fitotec Mex* **40**:55–63 (2017). (English abstract).
- 49 Osuna-García JA, Doyon G, Salazar-García S, Goenaga R and González-Durán IJL, Relationship between skin color and some fruit quality characteristics of 'Hass' avocado. *J Agric Univ P R* **95**:15–23 (2011).
- 50 Donetti M, Terry LA. INVESTIGATION OF SKIN COLOUR CHANGES AS NON-DESTRUCTIVE PARAMETER OF FRUIT RIPENESS OF IMPORTED ¿HASS¿ AVOCADO FRUIT. *Acta Horticulturae*. 2012; **945**:189–196. <http://dx.doi.org/10.17660/actahortic.2012.945.25>.
- 51 Woolf A, Clark C, Terander E, Phetsomphou V, Hofshi R, Arpaia L *et al.*, Measuring avocado maturity; ongoing developments. *Orchard*. **76**: 40–45 (2003) Available: <http://www.avocadosource.com/Journals/Orchardist/WoolfAllan2003b.pdf> [26 February 2019].

Anexo C: Artículo 2

Pattern Analysis and Applications (PAAA) manuscript No. (will be inserted by the editor)

NEW METHOD FOR INFERENCE OF SALT- AND-PEPPER NOISE LEVEL FROM TEXTURED IMAGES, BY STATISTICAL MEASURES OF RESIDUALS DISTRIBUTION IN LBP IMAGES

Vega, Jhon J. · Orjuela, Sergio A. ·
Wilfried Philips

Received: date / Accepted: date

Abstract Impulse noise, such as salt and pepper noise, reduce the characterization accuracy of subtleties in texture images. This problem is accentuated in video surveillance without a reference standard for calibration. Therefore, we proposed a new method for inferring the value of the assumed noise level of a textured image, without a reference pattern, using a model trained with the statistical measurements of the residuals distribution when computing LBP images. The experiments were performed on the Amsterdam Library of texture data set with different levels of salt and pepper noise. First, we demonstrated how the noise level influences the histogram distance of LBP calculated in circular neighborhoods of 8 and 12 points. Secondly, we calculated statistical measurements of the residuals distribution as the mean, median, standard deviation, kurtosis, skewness and the entropy. In addition, we estimate two statistics known as the alpha and beta values, considering the residuals distribution as a generalized Gaussian distribution. Then, four models were trained with this statistics to predict the salt and pepper noise level with the cross validation method. The most efficient was the neural network. Finally, we compared the proposed method with commercial methods such as Blind/Referenceless image spatial quality evaluator (Brisque), Naturalness Image Quality Evaluator (Nique), and Perception-Based Image Quality Evaluator (Pique). The result was that the neural network trained with the residual distribution using 8 and 12 points has a higher noise prediction efficiency in terms of the Pearson coefficient, the r-squared value and the mean squared error.

Keywords residuals distribution in LBP images · inference of noise level · textured image

Antonio Narino University
E-mail: jvega66@uan.edu.co

Antonio Narino University
E-mail: seorjuela@uan.edu.co

Universiteit Gent
E-mail: Wilfried.Philips@ugent.be

1 Introduction

Nowadays, image processing has gained importance as a basis for information processing. In particular, this field is widely used to evaluate local characteristics of an object. A challenge in this topic is to differentiate fine details or subtleties among the objects.

The perception of these details change due to external effects such as illumination, angle of the object, distance from the object, sensor quality and image quality among others [1]. The use of texture algorithms allows to measure local changes through the evaluation or relationships between pixel values [2]. This allows to analyze subtleties in images. Most texture algorithms are invariant to external factors. However, texture analysis methods are not efficient in case of low-light environments, low-contrast regions and noise [3].

It is important to consider that impulse noise in an image is a recurring problem due to transmission failures. Noise can also be present in image sensors with digital noise [4], the sensor introduces noise by the attribute of its materials, working environment, electrical components, circuit structure among others [5]. One of the types of impulse noise is known as salt and pepper, also called as the fixed valued impulse noise [6]. This problem is accentuated in surveillance cameras with low resolution and uncontrolled conditions. Measuring of noise level in an image can be performed by using methods with or without reference standards [7].

Images acquired in uncontrolled conditions such as those related to frames in surveillance videos do not allow the use of reference standards for calibration. However, the determination of noise in texture images without reference standard are not efficient. Because, "the majority methods are based on analyzing luminance edges" [8] while the texture is a homogeneous image.

An efficient technique to recognize local variations in an image is the one known as Local binary patterns (LBP) [9]. This technique is robust to variations in lighting and textures with low resolution images. The original LBP algorithm has evolved to different variations. Some of them have been used for face characterization [10], object identification in surveillance videos [11, 12, 13, 14], and object classification [15].

One of the variations can be used to characterize image textures with noise based on the use of a threshold value [16]. The threshold allows to extract the most relevant textural characteristics, with the presence of noise in the image [17]. However, most of the LBP variations based on threshold use an empirical limit to define the value [18]. Experiments demonstrate that the threshold value must be a function of the noise level [19].

The aim of this research is to present a method to predict the noise level of an image without a reference pattern, using statistical measurements of the residuals distribution in LBP images. This method will allow, for example the calculation of an adaptive threshold for LBP algorithms [20].

The LBP algorithm is based on the binary codification of the contrast of a reference pixel with its neighbours. However, when performing the binary codification, the subtleties of the image can be lost [21]. Thus, this paper propose to analyze the values, called the residuals, obtained from the comparisons among the pixel reference and its neighbours, performed before the process of codification. With this purpose, it is created an image using the residuals which are supposed to contain statistical information of the subtleties in the image [22].



Fig. 1: First 24 textures of the Amsterdam Library Of Textures (ALOT)

Since the LBP_residuals contain the subtleties of a texture, the statistical measurements on their distribution may characterize the noise level. Therefore, it is proposed to reduce the dimensionality of the information from its histogram. The histogram could be characterized which the generalized Gaussian distribution. Two statistical values can be calculated from the Laplacian distribution, namely, the alpha and beta values. The alpha value represents the scale and the beta value the shape [23]. Another way to characterize the image is the use of statistical measures of the distribution[24] such as: mean, median, standard deviation, kurtosis, skewness and entropy.

It is therefore proposed to:

Use a method to infer the assumed noise level value of a textured image, without a reference pattern, using a model trained with the statistical measurements of the residuals distribution.

2 Materials and methods

Texture quality assessment. The workflows to determine the quality of the image could be classified in direct, indirect and validation image quality. Direct image quality include a subjective and objective approaches, full and no-reference metrics [25]. We used a no-reference method with a training process [8]. We use three trained models: multiple linear regression, regression with support vector machine and neural network.

The proposed methods correspond to linear regressions. The measurement of the linear relationship between a predictor and the outcome variable was measured by the following metrics: adjusted coefficient of determination (R squared), mean squared error (RMSE) and Pearson's correlation coefficient [26].

Amsterdam Library of Textures (ALOT). is a color image collection of 250 rough textures, recorded for scientific purposes [27]. This database contains different angles of illumination of the object and different angles of rotation of the sensor.

2.1 LBP computation.

We use in this research the Local Binary Pattern based on circular neighbourhoods. The circular neighbourhood of a pixel is composed of N points equally spaced by




Fig. 2: Circular LBP8: 8 points within a 3 x 3 pixel windows.




Fig. 3: Circular LBP12: 12 points within a 5 x 5 pixel windows.

an angle $2\pi/N$ and located at a fixed radius r from the pixel. The radius r is calculated with the equation 1. The intensity value of the points are calculated through bilinear interpolation using the four surrounding neighbouring pixels [28]. In its basic implementation. We calculate the LBP based in 8 and 12 points.

$$\frac{\partial}{\partial r} \sum_{i=1}^n \left(\sqrt{r^2 - x_i^2 - y_i} \right) = 0. \quad (1)$$

The LBP image is calculated in three steps. First, we calculate the difference between the intensity value of central pixel and N point and it is assigned with 0 or 1 if is lower or higher. Second, the LBP-code is the results by reading out clock wise N bits resulting. Finally, the central pixel is assigned with the LBP-code.

Circular LBP8 image. This is a classical technique where we construct circular neighbourhoods using $N = 8$ and $r = 1$. The set of points around the central pixel within the neighbourhood is shown in Figure 2. We use a 3 x 3 pixel window to use the information of 8 pixels in the neighbourhood.

Circular LBP12 image. We use this configuration taking into account that it increases the discriminant power of the LBP technique by optimally arranging the points within a 5 x 5 pixel windows to use the information of 24 pixels in the neighbourhood. We construct circular neighbourhoods using $N = 12$ and $r = 1.7725$ [28]. The set of points around the central pixel within the neighbourhood is shown in Figure 3.

LBP_residual image. We construct a residual image by replacing each pixel in the image with the average mean of its corresponding LBP-residuals [20] as equation 2.

$$\bar{\epsilon}_{i,j} = \sum_{n=1}^N \epsilon_{i,j,n} \quad (2)$$

We calculate residual images from circular the LBP8 image and LBP12 image.

2.2 LBP statistics.

LBP histogram distance. We use the circular algorithms of LBP8 and LBP12 to prove the influence of noise in the determination of subtleties in a texture. The loss of reliability in texture characterization was measured with the distance between the histograms. Euclidean distance [29] (equation 3) and the square root of twice the Jensen-Shannon entropy (equation 4) [28] were implemented as a measure of the distance between histograms. The distance was calculated between the histogram of the original image (q) and the histogram of the image with noise (p).

$$D(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}. \quad (3)$$

$$k(p, q) = \sqrt{\left(D\left(p \parallel \frac{p+q}{2}\right) + D\left(q \parallel \frac{p+q}{2}\right) \right)}. \quad (4)$$

LBP residual statistics. Many researchers suggested reducing the dimensionality of texture data by calculating their statistical measures [30, 2]. Therefore, we extract statistics of the residuals distribution as mean, median, standard deviation, skewness, Kurtosis and Entropy. and characterize the LBP residual histogram with the α and β of Generalized Gaussian Distribution (GGD).

Image and video analysis use the Gaussian and Laplacian distributions [31, 32]. Both distributions are considered within the same family of symmetric distributions by the use of the GGD, and the signal can be modeled with this method [33]. The GGD is modelled in terms of μ defining the location, α defining the scale and β defining the shape of the distribution as follows:

$$GGD = \frac{\beta}{2\alpha\gamma\left(\frac{1}{\beta}\right)} e^{-\left(\frac{|x-\mu|}{\alpha}\right)^\beta}. \quad (5)$$

where x is a random variable. γ denotes the Gamma function $\gamma(x) = (x-1)!$. The parameter α defines the variance of the distribution while the parameter β is related to the kurtosis of the distribution. Within this family, a Gaussian distribution is described when $\beta = 2$ and a Laplacian distribution is described when $\beta = 1$ [34]. Several approaches have been proposed to estimate the parameters of the GGD using experimental data. We use a method based on estimating the GGD parameters from the observed data using the maximum likelihood method [20].

2.3 No-Reference Quality Assessment commercial Models [35]

The results of Brisque and Nique have a correlation with human perception [36], therefore they are included in this research.

Blind/Referenceless image spatial quality evaluator

(Brisque). It is an algorithm to evaluate image quality without reference, it evaluates the general distortion of the image using statistics of locally normalized luminance coefficients. Brisque extracts the characteristics of the image from the generalized Gaussian distribution or from the asymmetric generalized Gaussian distribution by adjusting the histogram of the normalized subtracted contrast coefficients of the image [37]. These features are taken to support the vector regression model trained in an image database. With the trained model, it provides an image quality rating. This metric is also used to evaluate video quality [38], Magnetic resonance imaging [39] and Textured contact-lens detection in iris biometrics [40], among others.

Naturalness Image Quality Evaluator (Nique) .

is based on the construction of a quality aware collection of statistical features based on space domain natural scene statistic model. These features are derived from a corpus of natural, undistorted images [41]. This metric has also been used to characterize the quality of: non-photographic images [42], restored movies [43] and magnetic resonance imaging [44], among others.

Perception-Based Image Quality Evaluator (Pique) .

This predicts quality from local characteristics, without prior training. For this, it generates a fine grain block level distortion map of perceptually significant regions of an image [45]. This algorithm has been used to verify the quality of different images. as example: 3d images where the sensors are in low light and high noise [46], cell phone images for medical diagnosis [47], and High-resolution three-dimensional (3D) structural magnetic resonance imaging [48], among others.

3 Experimental set-up

This research used five steps. First, the simulation of different noise levels in the ALOT database. Second, we prove the influence of noise in measuring the subtleties of a texture. Third, the statistical measurements of the residual images were determined. Fourth, we measure texture quality with three learning algorithms. Finally, the best learning algorithm was compared with three commercial algorithms. The implementation was in Matlab R2019b software [35].

We used from the ALOT database the images with viewing direction of zero degrees and all lights turned on, at a reddish spectrum of 2175K color temperature. 101 noise levels were simulated with the function salt and pepper. The noise level in the salt and pepper function used a range of 0 to 1. 25250 images of textures were obtained. An example of this step is presented in figure 4 item a. We present as an example the texture 250 (corn) of the database. The metrics calculated for this texture will be highlighted in the results of this research.

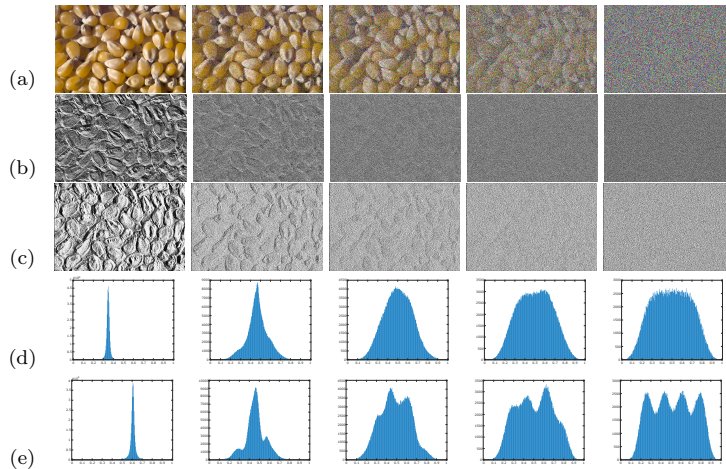


Fig. 4: Data for texture number 250 with salt and pepper noise levels at 0, 0.25, 0.50, 0.75 and 1 . a) Texture images; b) Circular LBP8 images; c) Circular LBP12 images; d) Circular LBP8_residual intensity histograms; e) Circular LBP12_residual intensity histograms.

Proving the influence of noise in measuring the subtleties of a texture. The subtleties of each texture were characterized by the histogram of the circular LBP code 8 and 12. We measure the distance between the histograms of the original image and the image with noise. Distances were measured by the Euclidean distance and the square root of twice the Jensen-Shannon entropy. An example of the calculated LBP images are shown in Figure 4, item b and c.

We calculated the LBP8_residual and LBP12_residual for 25250 texture images. An example of the calculated histogram of LBP_residual image are shown in Figure 4, item d and e. From the residuals distribution of LBP_residual image the mean, median, standard deviation, skewness, Kurtosis, Entropy, Alpha and the beta were calculated. The statistics of each image was a vector of 8 data. In the end two response matrices of 8 by 25250 were obtained. An example of the calculated LBP_residual statistics are shown in table 1.

Three models were trained with LBP8_residual statistics or LBP12_residual statistics. The models were trained by cross validation of 5 folds. For each validation 20200 training data and 5050 test data were used. We used the test data from the each fold to get the quality metrics. The quality metrics used were adjusted R square and root mean square Error. .

The commercial models were trained according to the recommendation [35]. In the case of niqe was trained with 250 images of original textures. The 25250 images were then tested with the niqe function [37]. In the case of the pique function, the database was divided into two, the first for training and the second for testing. The brisque function was trained with the first 125 textures and their noise levels (12625 texture images) [41]. The opinion score value is the noise level value multiplied by 100. The brisque function was tested with the other 12625 texture images. In the case of pique no training was used [45]. The test data were

Method	Noise level	Alpha	Beta	Mean	Median	Standard deviation	Skewness	Kurtosis	Entropy
LBP8_residual	0	0.274	0.464	0.350	0.349	0.028	4.269	3.905	47.409
	0.25	44.174	1.279	0.483	0.481	0.107	6.766	0.039	3.801
	0.5	95.455	2.479	0.499	0.499	0.147	7.263	0.012	2.620
	0.75	125.593	3.694	0.487	0.489	0.167	7.426	0.002	2.254
	1	146.508	4.610	0.500	0.499	0.189	7.579	0.002	2.107
LBP12_residual	0	0.515	0.470	0.605	0.607	0.040	4.757	-3.024	32.359
	0.25	42.843	1.193	0.485	0.483	0.109	6.753	0.024	3.916
	0.5	104.788	2.890	0.494	0.492	0.152	7.299	0.016	2.501
	0.75	137.731	6.402	0.521	0.522	0.183	7.508	0.007	2.049
	1	155.951	12.514	0.521	0.522	0.207	7.605	-0.004	1.860

Table 1: LBP8_residual statistics for texture number 250 with salt and pepper noise levels at 0, 0.25, 0.50, 0.75 and 1

used to get the quality metrics. The quality metrics used were adjusted R square and root mean square Error.

The neural network was trained with LBP8_residual statistics or LBP12_residual statistics. In order to present the comparison with parameters similar to the commercial models, the database was divided in two. The first 125 textures were used to generate the model. The neural network was trained with three quarters of the data (9468 vectors) and validated with one quarter of the data (3157 vectors). Test data (12625 vectors) were used to get the quality metrics. The quality metrics used were adjusted R squared, root mean squared error and Pearson’s correlation coefficient.

Each model was configured with standard parameters [35]. The regression with the support vector machine was executed with a linear kernel. The neural network was a hidden layer with eight neurons and trained with the Levenberg-Marquardt algorithm.

4 Results and discussion

The influence of noise on texture characterization is demonstrated in Figure 5. The influence of noise was measured as a function of two histogram distance metrics. Texture characterization was performed by two LBP algorithms. Figure 5 shows two stages in the distance of histograms. The first stage has a relationship proportional to the noise level. The second stage the distance does not present significant differences compared to the noise level. In the second stage the texture algorithm has been saturated with the noise level. It should be highlighted that the circular LBP12 with the Euclidean distance only presents characteristics of the first stage. In all the graphs there is a greater correlation between the distance and the noise level at 0.2 noise level.

Table 2 presents the results for three models trained with LBP_residual statistics vectors. Predicted values vs target have a correlation greater than 0.98. The regression model with the highest correlation is that of neural networks. The statistics with the lowest mean quadratic error are those of LBP8_residual. The model chosen for comparison with commercial models is neural network.

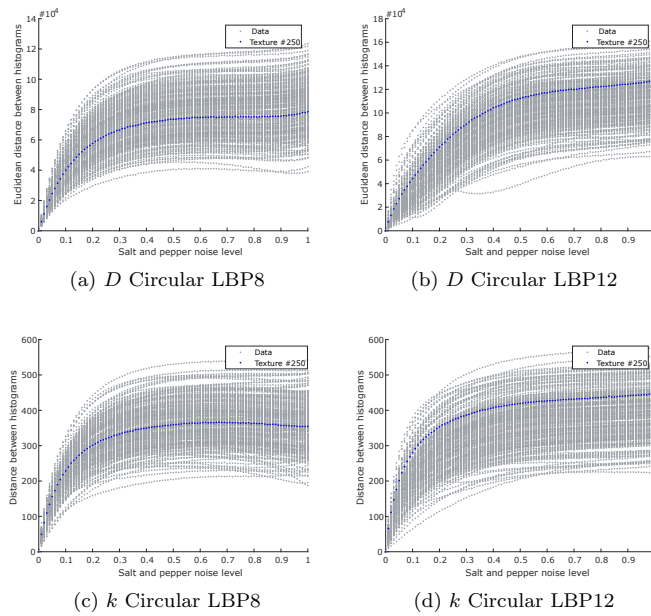


Fig. 5: Euclidean distance (D) and The square root of twice the Jensen-Shannon entropy (k) for histograms of circular LBP8 and circular LBP12 versus salt and pepper noise level. Highlighted data with blue for texture 250.

Model Method	MLR			LSVM			NN		
	A. R squared	RMSE	P. corr.	A. R squared	RMSE	P. corr.	A. R squared	RMSE	P. corr.
LBP8_residual s.	0.9899	0.0293	0.9950	0.9809	0.0403	0.9904	0.9989	0.0099	0.9994
LBP12_residual s.	0.9899	0.0293	0.9949	0.9809	0.0403	0.9904	0.9990	0.0093	0.9995

Table 2: Accuracy metrics for the predicted noise level versus target noise level for three trained models for two LBP_residual methods. Accuracy metrics: Adjusted R square, Root Mean Square Error (RMSE) and Pearson's correlation coefficient. Models: multiple linear regression (LMR), linear regression with support vector machine (LSVM) and neural network (NN).

Figure 6 shows the relationship between the prediction of each model and the noise level of the texture. The graph shows that the pique model has no correlation with the target as of 0,2 noise level . The Nique model data show correlation fluctuations at different noise levels. When reviewing the precision metrics in table 3, it can be seen that the proposed model has a higher r-squared. The model trained with the LBP8_residual method has the lowest mean squared error.

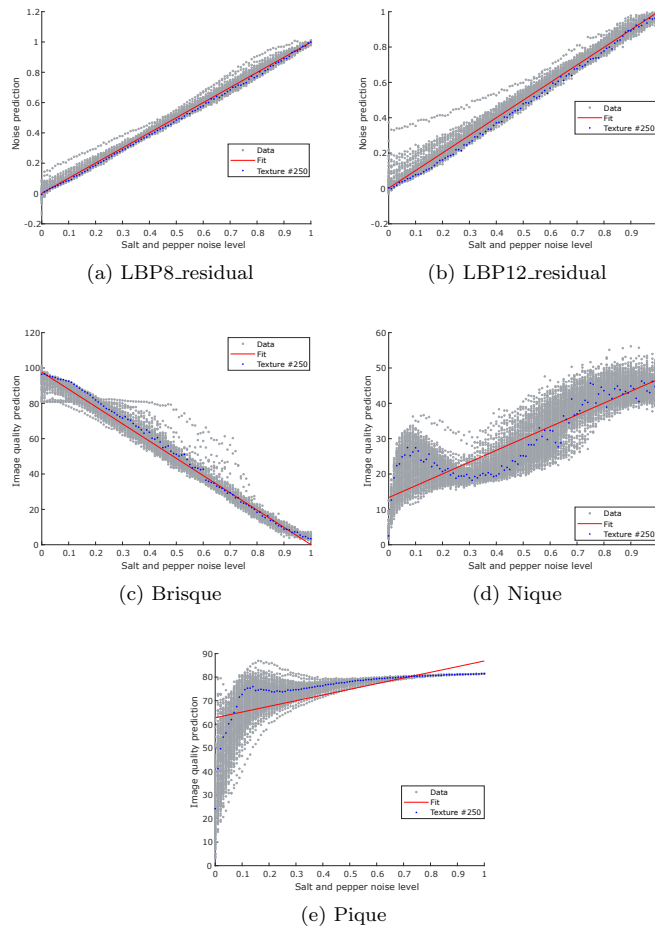


Fig. 6: Regression for the predicted noise level or image quality prediction versus target noise level for five models. a) Neural network trained with LBP8_residual statistics b) Neural network trained with LBP12_residual statistics, c) Brisque model, d) Nique model and e) Pique model. Highlighted data with blue for texture 250.

5 Conclusions and future work

The characterization of textures is influenced by the noise level. The influence was checked by two methods to measure the distance between histograms. Comparing the circular technique LBP12 with the circular technique LBP8, it presents an efficient characterization of the subtleties because the interpolated values of the sampling points are not influenced by the value of the central pixel. This is showed

Model	A. R squ.	RMSE	P. corr.
N.N. LBP8_residual s.	0.9961	0.0181	0.9988
N.N. LBP12_residual s.	0.9922	0.0258	0.9961
Brisque	0.9866	3.3173	-0.9933
Nique	0.8054	4.7897	0.8974
Pique	0.4709	7.4412	0.6863

Table 3: Accuracy metrics for the predicted noise level or image quality prediction versus target noise level for five models. Accuracy metrics: Adjusted R squared, Root Mean Squared Error (RMSE) and Pearson’s correlation coefficient. Models: Neural Network with LBP8_residual statistics, Neural Network with LBP12_residual statistics, Blind/Referenceless image spatial quality evaluator (Brisque), Naturalness Image Quality Evaluator (Nique), and Perception-Based Image Quality Evaluator (Pique).

by the distance of histograms of the circular technique LBP12, which presented a greater relationship with the noise level.

The proposed method makes it possible to predict the level of salt and pepper noise induced to a texture. To evaluate the prediction efficiency, texture metrics were used that were not used in the training. The model trained with the proposed method with the greatest efficiency is that of neural networks. The prediction of the neural network model has less error than the commercial models evaluated. The model trained with LBP8_residual statistics has the lowest prediction error.

The next steps are to evaluate other statistical metrics of the LBP_residual image. Evaluate the method for other texture quality features. Use the expected quality value for the generation of an adaptive threshold for LBP algorithms.

References

1. R. W. Fleming, Material Perception, Annual Review of Vision Science, vol. 3, pp. 365–388 (2017).
2. P. Simon and V. Uma, Review of texture descriptors for texture classification, Advances in Intelligent Systems and Computing, vol. 542, pp. 159–176 (2018)
3. X. Hu, Y. Huang, X. Gao, L. Luo, and Q. Duan, Squirrel-cage local binary pattern and its application in video anomaly detection, IEEE Transactions on Information Forensics and Security, vol. 14, no. 4, pp. 1007–1022 (2019).
4. F. Sanson and C. Frueh, Noise estimation and probability of detection in non-resolved images: Application to space object observation, Advances in Space Research, vol. 64, no. 7, pp. 1432–1444 (2019).
5. C. Ma, X. Lv, and J. Ao, Difference based median filter for removal of random value impulse noise in images, Multimedia Tools and Applications, vol. 78, no. 1, pp. 1131–1148 (2019).
6. A. Q. Md. Taha and H. Ibrahim, “Reduction of salt-and-pepper noise from digital grayscale image by using recursive switching adaptive median filter,” Lect. Notes Mech. Eng., pp. 32–47 (2020).
7. A. V. Murthy and L. J. Karam, A MATLAB-based framework for image and video quality evaluation, in 2010 2nd International Workshop on Quality of Multimedia Experience, QoMEX 2010 - Proceedings, pp. 242–247 (2010).
8. M.-J. Chen and A. C. Bovik, “No-reference image blur assessment using multiscale gradient,” EURASIP J. Image Video Process., vol. 2011, no. 1, p. 3 (2011).
9. T. Ojala, M. Pietikäinen, and D. Harwood, A comparative study of texture measures with classification based on featured distributions, Pattern Recognition, vol. 29, no. 1, pp. 51–59 (1996).

10. M. Kas, Y. El Merabet, Y. Ruichek, and R. Messoussi, Survey on local binary pattern descriptors for face recognition, *ACM International Conference Proceeding Series* (2019).
11. R. Singh, A. K. S. Kushwaha, and R. Srivastava, Multi-view recognition system for human activity based on multiple features for video surveillance system, *Multimedia Tools and Applications*, vol. 78, no. 12, pp. 17165–17196 (2019).
12. Mohana and H. V Ravish Aradhya, Simulation of object detection algorithms for video surveillance applications, *Proceedings of the International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud), I-SMAC 2018*, pp. 651–655 (2019).
13. Z.-T. Liu, S.-H. Li, W.-H. Cao, D.-Y. Li, M. Hao, and R. Zhang, Combining 2D Gabor and local binary pattern for facial expression recognition using extreme learning machine, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, vol. 23, no. 3, pp. 444–455 (2019).
14. M. A. Kandavalli and S. Abraham Lincon, Design and implementation of colour texture-based multiple object detection using morphological gradient approach, *Concurr. Comput.*, vol. 31, no. 14 (2019).
15. L. Liu, P. Fieguth, Y. Guo, X. Wang, and M. Pietikäinen, Local binary features for texture classification: Taxonomy and experimental study, *Pattern Recognition*, vol. 62, pp. 135–160 (2017).
16. M. M. Rahman, S. Rahman, M. Kamal, M. Abdullah-Al-Wadud, E. K. Dey, and M. Shoyaib, Noise adaptive binary pattern for face image analysis, in *2015 18th International Conference on Computer and Information Technology, ICCIT 2015*, pp. 390–395 (2016).
17. S. M. Tabatabaei and A. Chalechale, Noise-tolerant texture feature extraction through directional thresholded local binary pattern, *Visual Computer*, (2019).
18. H. C. Lee, B. J. Kang, E. C. Lee, and K. R. Park, Finger vein recognition using weighted local binary pattern code based on a support vector machine, *Journal of Zhejiang University SCIENCE C*, vol. 11, no. 7, pp. 514–524, Jul. (2010).
19. M. Alkhatib and A. Hafiane, Robust Adaptive Median Binary Pattern for Noisy Texture Classification and Retrieval, *IEEE Transactions on Image Processing*, vol. 28, no. 11, pp. 5407–5418 (2019).
20. S. A. Orjuela-Vargas, J. Triana-Martinez, J. P. Yañez, and W. Philips, Real time algorithm invariant to natural lighting with LBP techniques through an adaptive thresholding implemented in GPU processors, in *Proceedings of SPIE - The International Society for Optical Engineering*, vol. 9023 (2014).
21. P. G. Freitas, L. P. Da Eira, S. S. Santos, and M. C. Q. De Farias, On the application LBP texture descriptors and its variants for no-reference image quality assessment, *J. Imaging*, vol. 4, no. 10 (2018).
22. A. Rodriguez, S. A. O. Vargas, and W. Philips, Robust video feature extraction invariant to natural lighting by using LBP techniques with adaptive thresholding, in *Symposium of Signals, Images and Artificial Vision - 2013, STSIVA 2013* (2013).
23. H. Li, W. Hu, and Z.-N. Xu, Automatic no-reference image quality assessment, *Springerplus*, vol. 5, no. 1 (2016).
24. B. Al-Saedi, Alsaedi, B. Jaffer Sadiq Al-khafaji, S. Abed, and A. Wahab, Content Based Image Clustering Technique Using Statistical Features and Genetic Algorithm, *Engineering, Technology and Applied Science Research*, vol. 9, pp. 3892–3895 (2019).
25. G. Ciocca, S. Corchs, F. Gasparini, and R. Schettini, How to assess image quality within a workflow chain: an overview, *International Journal on Digital Libraries*, vol. 15, no. 1 (2014).
26. K. H. Zou, K. Tuncali, and S. G. Silverman, Correlation and simple linear regression, *Radiology*, vol. 227, no. 3, pp. 617–622 (2003).
27. G. J. Burghouts, J.-M. Geusebroek, Material-specific adaptation of color invariant features, *Pattern Recognition Letters*, vol. 30, no. 3, pp. 306–313 (2009).
28. S. A. Orjuela Vargas, J. P. Yañez, and W. Philips, The Geometric Local Textural Patterns (GLTP) technique, in *Local binary patterns : new variants and new applications*, vol. 506, pp. 30–70, Eds. Springer (2014).
29. S. Wang et al., Content-based image retrieval based on improved rotation invariant LBP descriptor, in *Proceedings - 2019 IEEE International Congress on Cybermatics: 12th IEEE International Conference on Internet of Things, 15th IEEE International Conference on Green Computing and Communications, 12th IEEE International Conference on Cyber, Physical and Social Computing and 5th IEEE International Conference on Smart Data, iThings/GreenCom/CPSCoM/SmartData 2019*, pp. 1211–1216 (2019).

30. M. Gupta, V. Rajagopalan, and B. V. V. S. N. P. Rao, Glioma grade classification using wavelet transform-local binary pattern based statistical texture features and geometric measures extracted from MRI, *Journal of Experimental and Theoretical Artificial Intelligence*, vol. 31, no. 1, pp. 57–76 (2019).
31. N. Nacereddine, A. B. Goumeidane, and D. Ziou, Unsupervised weld defect classification in radiographic images using multivariate generalized Gaussian mixture model with exact computation of mean and shape parameters, *Computers in Industry*, vol. 108, pp. 132–149 (2019).
32. L. Yang, Y. Yang, and Y. Ma, A novel no-reference video quality assessment algorithm, in *Proceedings of 2018 IEEE 4th Information Technology and Mechatronics Engineering Conference, ITOEC 2018*, pp. 181–187 (2018).
33. R. Krupiński, Modeling quantized coefficients with generalized gaussian distribution with exponent $1/m$, $m=2,3,\dots$, *Advances in Intelligent Systems and Computing*, vol. 659, pp. 228–237 (2018).
34. H. Hu, L. Huang, and W. Yu, Aircraft detection for hr sar images in non-homogeneous background using GGMD-based modeling, *Chinese Journal of Electronics*, vol. 28, no. 6, pp. 1271–1280 (2019).
35. MATLAB, “MATLAB and Image Processing Toolbox Release 2019b,” MATLAB. (2019).
36. Y. Yang, X. Cai, M. Zhang, and X. Xiao, Reversible data hiding with different embedding capacity based on optimal embedding strategy selection and image quality assessment criteria, *Journal of Information Hiding and Multimedia Signal Processing*, vol. 10, no. 2, pp. 392–407 (2019).
37. L. Zheng, L. Shen, J. Chen, P. An, and J. Luo, No-Reference Quality Assessment for Screen Content Images Based on Hybrid Region Features Fusion, *IEEE Transactions on Multimedia*, vol. 21, no. 8, pp. 2057–2070 (2019).
38. S. Goring, R. R. R. Rao, and A. Raake, Nofu - A lightweight no-reference pixel based video quality model for gaming content, in *2019 11th International Conference on Quality of Multimedia Experience, QoMEX 2019* (2019).
39. M. Sandilya and S. R. Nirmala, Determination of reconstruction parameters in Compressed Sensing MRI using BRISQUE score, in *2018 International Conference on Information, Communication, Engineering and Technology, ICICET 2018* (2018).
40. H. Mandalapu, R. Ramachandra, and C. Busch, Image Quality and Texture-Based Features for Reliable Textured Contact Lens Detection, in *Proceedings - 14th International Conference on Signal Image Technology and Internet Based Systems, SITIS 2018*, pp. 587–594 (2018).
41. A. Mittal, R. Soundararajan, and A. C. Bovik, Making a ‘completely blind’ image quality analyzer, *IEEE Signal Processing Letters*, vol. 20, no. 3, pp. 209–212 (2013).
42. S. Paul and A. C. Bovik, Image Statistic Models Characterize Well Log Image Quality, *IEEE Geoscience and Remote Sensing Letters*, vol. 16, no. 7, pp. 1130–1134 (2019).
43. A. R. Al-Shamasneh, H. A. Jalab, S. Palaiahnakote, U. H. Obaidellah, R. W. Ibrahim, and M. T. El-Melegy, A new Local Fractional Entropy-Based model for kidney MRI image enhancement, *Entropy*, vol. 20, no. 5 (2018).
44. A. Plutino, M. P. Lanaro, S. Liberini, and A. Rizzi, Work memories in Super 8: Searching a frame quality metric for movie restoration assessment, *Journal of Cultural Heritage* (2019).
45. N. Venkatanath, D. Praneeth, B. H. Maruthi Chandrasekhar, S. S. Channappayya, and S. S. Medasani, Blind image quality evaluation using perception based features, in *2015 21st National Conference on Communications, NCC 2015* (2015).
46. A. Markman, T. O’Connor, H. Hotaka, S. Ohsuka, and B. Javidi, Three-dimensional integral imaging in photon-starved environments with high-sensitivity image sensors, *Optics Express*, vol. 27, no. 19, pp. 26355–26368 (2019).
47. P. Ganesan, Z. Xue, S. Singh, R. Long, B. Ghoraani, and S. Antani, Performance Evaluation of a Generative Adversarial Network for Deblurring Mobile-phone Cervical Images, in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 4487–4490 (2019).
48. A. Cristobal-Huerta, D. H. J. Poot, M. W. Vogel, G. P. Krestin, and J. A. Hernandez-Tamames, Compressed Sensing 3D-GRASE for faster High-Resolution MRI, *Magnetic Resonance in Medicine*, vol. 82, no. 3, pp. 984–999 (2019).

Anexo D: Artículo 3



Article

Solar Panel Detection within Complex Backgrounds Using Thermal Images Acquired by UAVs

Jhon Jairo Vega Díaz ^{1,*} , Michiel Vlaminck ² , Dionysios Lefkaditis ³,
Sergio Alejandro Orjuela Vargas ⁴ and Hiep Luong ²

¹ Centro de Investigación en Ciencias Básicas y Aplicadas, Doctorado en Ciencia Aplicada, Universidad Antonio Nariño (UAN), 110231 Bogotá, Colombia

² Telecommunications and Information Processing (TELIN), Ghent University, Imec, B-9000 Ghent, Belgium; michiel.vlaminck@ugent.be (M.V.); hiep.luong@ugent.be (H.L.)

³ Sitemark, Gaston Geenslaan 11, 3001 Leuven, Belgium; dionysios.lefkaditis@sitemark.com

⁴ Facultad de Ingeniería Mecánica Electrónica y Biomedica, Universidad Antonio Nariño (UAN), 730001 Ibagué, Tolima, Colombia; seorjuela@uan.edu.co

* Correspondence: jvega66@uan.edu.co

Received: 28 September 2020; Accepted: 28 October 2020; Published: 31 October 2020



Abstract: The installation of solar plants everywhere in the world increases year by year. Automated diagnostic methods are needed to inspect the solar plants and to identify anomalies within these photovoltaic panels. The inspection is usually carried out by unmanned aerial vehicles (UAVs) using thermal imaging sensors. The first step in the whole process is to detect the solar panels in those images. However, standard image processing techniques fail in case of low-contrast images or images with complex backgrounds. Moreover, the shades of power lines or structures similar to solar panels impede the automated detection process. In this research, two self-developed methods are compared for the detection of panels in this context, one based on classical techniques and another one based on deep learning, both with a common post-processing step. The first method is based on edge detection and classification, in contrast to the second method is based on training a region based convolutional neural networks to identify a panel. The first method corrects for the low contrast of the thermal image using several preprocessing techniques. Subsequently, edge detection, segmentation and segment classification are applied. The latter is done using a support vector machine trained with an optimized texture descriptor vector. The second method is based on deep learning trained with images that have been subjected to three different pre-processing operations. The postprocessing use the detected panels to infer the location of panels that were not detected. This step selects contours from detected panels based on the panel area and the angle of rotation. Then new panels are determined by the extrapolation of these contours. The panels in 100 random images taken from eleven UAV flights over three solar plants are labeled and used to evaluate the detection methods. The metrics for the new method based on classical techniques reaches a precision of 0.997, a recall of 0.970 and a F_1 score of 0.983. The metrics for the method of deep learning reaches a precision of 0.996, a recall of 0.981 and a F_1 score of 0.989. The two panel detection methods are highly effective in the presence of complex backgrounds.

Keywords: solar panel detection; solar panel projection; texture descriptor; support vector machine; deep learning; NIR; thermal imaging

1. Introduction

The increased use of renewable and low-carbon energy has led to economic [1] and environmental benefits [2]. Among the renewable sources is the use of solar energy in for example on the rooftop

of houses [2,3], buildings [4] or on wide fields for power plants [5]. Solar energy is commonly captured by photovoltaic panels. However, the efficiency of the panels is deteriorates in the presence of anomalies, such as hot spots. Hot spots occur due to non-uniform energy generation between the photo-voltaic cells, with differences that exceed 5% of the temperature admitted in standard test periods. These sudden temperature rises have the potential to lead to spontaneous ignition [6].

Anomalies in solar panels lead to energy and temperature changes, so they are measured with current and voltage indicators [7,8] and thermal sensors [9–11]. The anomalies measured by thermal sensors are changes in energy efficiency [12], material fatigue [13,14] and hot spots [15,16]. However, hot spots can be catalogued at different levels of failure, which are associated with their geometry [17]. Since the classification of anomalies with thermal cameras is based on their geometry, a first step for their correct classification is the identification of the solar panel. Related research has also focused on the detection of the solar panels array [18,19].

Due to the creation of large solar plants, it has been required to incorporate the use of drones for the inspection of massive amounts of solar panels [20]. The images generated by this technology, when processed with photogrammetric methods, allow generating orthomosaics and incorporating thermal and RGB image layers to geographic information systems (GIS) [21–23]. For the identification of the panels, information from the thermal image has been used, together with the RGB image [24] or the 3D models [25]. However, the developments are focused on the identification of the panels using only thermal video [26,27] or thermal imaging [28].

Panel detection focuses on identifying rectangular structures. However, this identification is difficult in thermal images because not all panel edges are visible [24] and because of irregularities by weeds shades, sunlight reflection [20] or hot spots. By adding this type of diagnostic difficulties with other variables such as different flight heights, changes in lighting [29], panel like structures, energy lines and images with lens distortion, which are all considered as complex backgrounds [30] (Figure 1).

The identification of solar panels in thermal images with complex backgrounds has five challenges:

1. Hot spots create an atypical distribution of data, which leads to a loss of image contrast.
2. The edges suffer from distortion and diffusion.
3. There are structures that have a panel-like geometry.
4. Edge detection fails due to image saturation in areas with hot spots or sunlight reflections.
5. Other occlude obstruct the panel, making its full geometry invisible.




Figure 1. Examples of problems in thermal imaging acquired with drones with complex backgrounds. (a) Sunlight reflection. (b) Energy lines. (c) Poorly defined panel edges. (d) Like panel structures. (e) weeds shades. (f) Edges distortion by hot spots. (g) Lens distortion. (h) Display of up to 350 panels per image.

This paper focuses on the first step for a proper diagnosis of the fault, in which a solar panel detection is necessary to delimit the region of interest for the detection and classification of the anomaly, because the correct classification is based on geometries in the panel or between panels. The development of methodologies for the detection of solar panels directly from the thermal image will allow the design of a fully automated anomaly classification system with real time processing. Therefore, this work is focused on reducing panel detection failures, since those that are not detected are those that typically contain anomalies. So, the main contributions are:

1. A novel method based on classical Machine Learning is developed for the detection of solar panels using effective preprocessing steps.
2. our novel method based on classical Machine Learning approach is compared against a state-of-the-art Deep Learning algorithm.
3. A novel method predicting missing (i.e., undetected) solar panels. This method is used as a post-processing step for both detection algorithms: based on classical techniques and deep learning. The post-processing improves the recall of both methods.

Related Work

From the investigations with images taken with drones that only use thermal images as reference, some researches only focused on detecting the damage without discriminating the panels. To identify the damage, they calculate the temperature difference [31] with Canny edge detection [26]. However, the presence of hot spots creates an atypical distribution of data, which leads to a loss of image contrast, making it difficult to identify the panels. Alternatively, the panels were segmented by the following methods: Template Matching [32], segmenting the image using k-means clustering [33], the active contour level sets method (MCA) and the area filtering (AF) approach [28]. These methods have been referred to as classical methods, which fail to focus only on identifying panels and do not include a method for differentiating them from the environment with panel-like structures.

For the detection of the panels among the models used in deep learning are: an algorithm based on a fully convolutional neural network and a dense conditional random field [30] and a convolutional neural network framework called ‘You Only Look Once’ (YOLO) [29]. However, the presence of energy lines creates atypical geometries that none of the methods can overcome.

The weaknesses of the related works are grouped into three categories: the first category focuses only on the detection of hot spots; the second category uses photos with panels in high resolution and do not reference solutions for the features of the complex backgrounds; the third category handles deep learning techniques, but does not propose methods for projecting the missing panels. This information is presented in more detail in Table 1.

Table 1. Comparison between the proposed method and other research identifying solar panels using only thermal images with a complex background.

Method	Description	Weaknesses
Dhimish et al. [34]	Identifies hot spots in an RGB image with a color ramp.	Does not identify the affected solar panel. The thermal images have only a panel in high resolution.
Libra et al. [35]	Identifies hot spots in an RGB image with a color ramp.	Does not identify the affected solar panel. Does not segment the image
Liao et al. [31]	Identifies hot spots in an RGB image with a color ramp. Classic method based on filters for a binary classification of the image between faulty and non-faulty areas.	Does not identify the affected solar panel. Assumes that in all the photo there are only panels Lacks of methods to classify segments.
Alsafasfeh et al. [26]	Segmentation based on hot pixels detection. Classic method based on Canny edge detection	Does not identify the affected solar panel. Lacks of methods to classify segments.
Addabbo et al. [32]	Panel detection with classic methods based on template matching using normalized cross-correlation Tested on large dataset	The thermal images present a few panels in high resolution. It does not report or present solutions for the feautres 1, 4, and 5 of the complex background.
Alfaro-Mejía et al. [28]	Classic method based on two techniques. Performs an image transformation to orthogonize the detected panel	The thermal images present a few panels in high resolution. It does not present solutions for any of the complex backgrounds

Table 1. Cont.

Method	Description	Weaknesses
Uma et al. [33]	Classic method with segmentation of the image using the k-means clustering algorithm.	k-means is an unsupervised classification. It does not present solutions for the features 3, 4, and 5 of the complex background.
Zhu et al. [30]	learning with an algorithm based on a fully convolutional neural network and a dense conditional random field	It does not propose a solution to identify panels that remained undetected by the deep learning method.
Greco et al. [29]	Deep learning with a convolutional neural network framework called 'You only Look Once' (YOLO) Tested on large dataset	It does not propose a solution to identify panels that remained undetected by the deep learning method.

2. Materials and Methods

2.1. Experimental Setup and Study Area

The thermal images were acquired with a DJI Zenmuse XT camera developed by FLIR [36], with 640×520 pixels, in TIF format with 14 bits. The data set contains 11 flights from three different solar plants, with a relative flight height of 34 to 56 m. The images acquired from these solar plants presented have complex backgrounds, and all the analysis is based only on the information available in the thermal image, so, other flight plan information is not included. In total, 18,244 panels are delimited out of 100 randomly selected thermal images.

Image processing was coded in the python 3 language with CUDA toolkit, the principal libraries are NumPy [37], OpenCV [38], scikit-image [39], SimpleITK, PyRadiomics [40,41] and Detectron 2 [42].

The new method based on classical techniques is described in Section 2.2. The method based on deep learning is described in Section 2.3. These methods are evaluated with the precision metrics described in Section 2.4.

2.2. Solar Panel Detection Using Our New Method Based on Classical Techniques

The first method to detect solar panels consists of the following steps: first an image correction; second, an image segmentation; third, a segment classification with machine learning; finally, a post-processing step based on the detected panels (Figure 2). The proposed method highlights the use of the OpenCV library, since it allows to calculate a contour and its characteristics such as: the image area, a rotated rectangle, the angle of rotation and convert the contour into a segment of the image, among others [38].

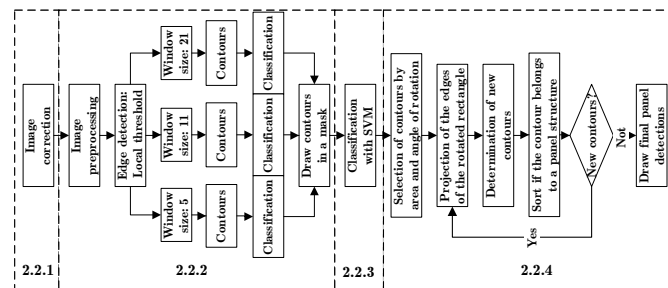


Figure 2. Method based on classical techniques and the numbers of the sections where the algorithm is described.

2.2.1. Image Correction

In image processing some data normalization steps are often required. However, in cases where hot spots or areas with sun reflection occur, the normalization implies the generation of images with low contrast and loss in the textural characteristics. Therefore, to avoid the loss of subtleties in the image it is proposed to remove the outlier data in the following way: the average plus twice the

standard deviation is used as the reference value. Outliers are corrected if less than 5 percent of the data exceeds the reference value. To reduce the distribution tail, the outliers are assigned to the reference value (See Figure 3).




Figure 3. Image correction to reduce the effect of hot spots or sun reflection: (a) the original image; (b) the histogram with the probability distribution function and the values of the mean and twice the standard deviation; (c) the corrected image.

2.2.2. Image Segmentation

The detection of panels is based on the detection of their edges, which have a temperature lower than the center of the panel. Among the basic concepts used is that panels are four-sided structures that can be simplified as rectangles. However, solar panels on complex backgrounds have anomalies that lead to distortions, loss of continuity at the edges and diffuse edges that make it difficult to detect the rectangles. Therefore, the proposed algorithm consists of an image preprocessing, edge detection and segment determination. The image preprocessing uses a convolution filter, a bilateral filter and a gamma correction. The edge detection involves threshold settings at different ranges in order to determine most of the image edges. Each edge detection process involves the calculation of contours that are evaluated in shape and size. These contours are drawn as a mask in an iterative way in an image, which at the end collects all the segmentations made.

Correct line detection is based on changes in the pixel values that identify a border. However, the edges of certain panels are represented only by a dashed line one pixel wide and therefore our method seeks to make these types of edges visible. The image preprocessing has the following steps: first, a convolution filter is used with the following mask [1 1 1; 1 1 1; 1 1 1]. Usually, this filter is used in other contexts to generate noise, but in this case it is used to increase the width of the edge due to the displacement of the data by one pixel around it. Second, in certain panels in their corners there are no marked differences in temperature with their surroundings and in other cases the edges are diffuse, so a bilateral filter is used to homogenize the data in 3-pixel windows with the aim of emphasizing the borders. So, the bilateral filter is applied with the following configuration: 3 range pixels, a sigma filter for the color space of 200 and a sigma filter in space coordinates of 50. With this configuration, the edges are preserved by having a greater variation in intensity between the pixels. Third, In order to emphasize the edges of the panels that do not contrast with their surroundings, the contrast of the image is enhanced by using a gamma correction with a very high value such as 4.8 (Figure 4a). The value was selected after evaluating different settings on images with low edge contrast.

The temperature of the panels edges vary locally. Therefore, the edge detection uses an adaptive threshold, but the widths of the panel edges are of variable size. Therefore, our algorithm is used with three windows of different width (5, 11 and 21) so that with each pixel window panels are detected that with the other one are not (Figure 4b). After thresholding each of the images, edge detection is performed, calculating the internal contours of the panels. Since a panel is a rectangular structure, this step seeks to determine whether a segment contain that characteristic. The segment determination consists of a classification of the contours by their image area, the number of corners and their solidity.

The contours are selected if they have: an area between 100 square pixels and the expected panel size, three to four corners and a solidity greater than 0.8. The contour is used to determine an area of the image called a segment, It is assumed that an segment smaller than 100 square pixels does not represent a panel. The number of contour corners are counted from the approximation of the contour to a shape with an OpenCV function using the Ramer–Douglas–Peucker algorithm. “Solidity is the ratio of contour area to its convex hull area” [38]. Finally, The segments are eroded to avoid overlapping and these are drawn as a mask on a zero matrix shaped like the original image (Figure 4c). To facilitate the evaluation each segment is drawn with a different color on the grayscale corrected image (Figure 4d).

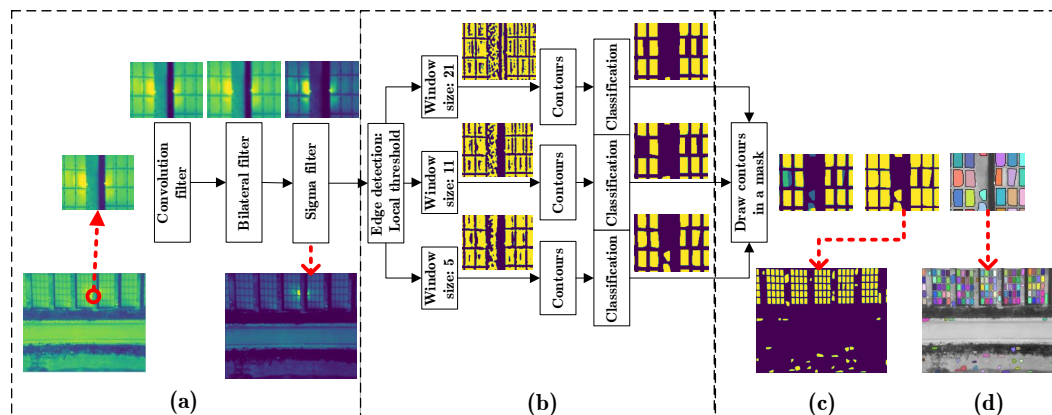


Figure 4. The image segmentation. (a) Image reprocessing. (b) Edge detection. (c) Mask with segments. (d) Panel detection of the first step.

2.2.3. Panel Classification with Svm

This is one of the most important steps of the proposed algorithm, because up to this point there is a series of contours that has a similar shape to a rectangle, but it is not known if this is a panel or not, so the method uses a supervised classification process based on the texture of the panels.

Using the mask with rectangular segments, the contours are calculated again. Each contour is converted to a segment of the image and this is dilated by circular structure element with a 6 pixel diameter to include the panel edges. An optimized set of texture descriptors are calculated for each segment, and it is classified whether it corresponds to a panel or not using a support vector machine (SVM).

The texture descriptors are calculated with the PyRadiomics library. This is a library developed for the extraction of features from medical images, which are based on texture descriptors. However, this library was chosen because it implements different transformations in the original image and characterizes it with different texture descriptors, allowing to evaluate subtle changes of the image. Moreover, with a configuration for 2D images it can be used in other contexts. The algorithm requires an image and a mask of the feature extraction area. The images must be converted to a Insight ToolKit image (ITK) [43] with the SimpleITK library. Two elements are parameterized in order to calculate as many features as possible. The algorithms that characterize the image with the specific texture descriptors (FeatureClass) and the image type (ImageType) which is the original image and its transformations. Six algorithms for texture descriptors (shape2D, firstorder, Gray Level Co-occurrence Matrix (GLCM), Gray Level Run Length Matrix (GLRLM), Gray Level Size Zone Matrix (GLSZM) and Gray Level Dependence Matrix (GLDM)) are applied on five transformed images (Original, LoG, sigma [3.0, 5.0] and Wavelet). This results in a total of 440 texture descriptors [40]. In this case the use of the image generated by the local and binary pattern algorithm was excluded because it was not efficient for classification.

A support vector machine is then used for the classification of a texture descriptor vector. Due to the amount of data, it uses the implementation of a regularized linear model with

stochastic gradient descent (SGD) learning. The ten-fold cross validation method is used to determine the classification accuracy. After evaluating different configurations, a larger classification efficiency is obtained by: standardization of features by removing the mean and scaling to unit variance, $\text{max_iter} = 1000$, $\text{class_weight} = \text{"balanced"}$, $\text{learning_rate} = \text{"adaptive"}$, $\text{eta0} = 0.5$, $\text{penalty} = \text{"elasticnet"}$, and $\text{tol} = 1 \times 10^3$ [39,44].

The optimized texture descriptor group is calculated from a created database of texture descriptors with data corresponding to two classes: solar panels and other objects. The descriptors with a probability of less than 0.001 in an ANOVA test and a classification accuracy with SVM of more than 90 percent in cross validation are selected. Finally, a mask is created with the selected contours corresponding to the solar panels of the thermal image. To facilitate the evaluation each segment is drawn with a different color on the grayscale image (Figure 5).

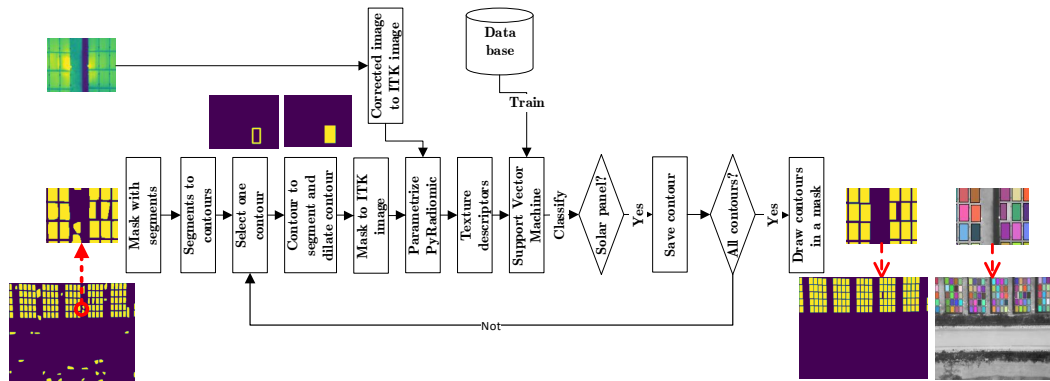


Figure 5. Panel classification with support vector machine.

2.2.4. Post-Processing

A final step is proposed in which the detected panels are used to infer the location of the panels that possibly remained undetected. This algorithm includes three steps: first, the selection of contours by image area and angle of rotation; second, the projection of edges of each rotated rectangle; third, the determination of new contours and their classification. The last two steps are repeated until no new contours are selected.

The selection of the contours of the detected panels is based on the following premises: the solar panels have four sides, the edges of the image have cut-out panels and most of the contours are solar panels. Therefore, each contour can be simplified to a rotated rectangle and the coordinates of the image where there are incomplete panels are related to the coordinates of the rotated rectangle. The rotated rectangle is composed of four points in the image, these points are represented by X and Y coordinates. The maximum X and Y shift value between points of each rotated rectangle is calculated and stored in a matrix. Finally, the section of the image border with incomplete panels, is calculated from the maximum value of the matrix of displacements in X and Y, plus a 20%. It is assumed that the region where there are incomplete panels is a rectangle with an edge shift towards the center with the maximum X value for vertical edges and the maximum Y value for horizontal edges. Thus, excluding the panels at the edges, the average area and the angle of rotation of the rotated rectangles are calculated. For the panels at the edges only the angle of rotation of the contour is calculated. Because images suffer from lens and perspective distortions, the contours with a 20% deviation from the rotation angle and a deviation of 20% below and 30% above the average area are eliminated (Figure 6).

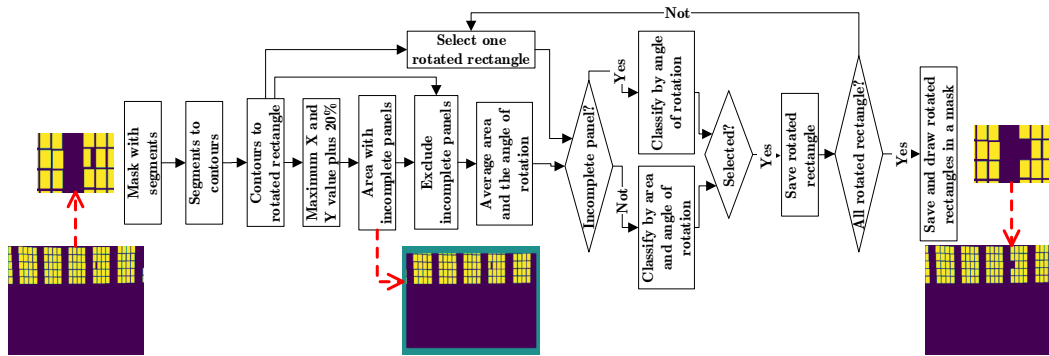


Figure 6. Selection of the contours of the detected panels, one panel is missing.

The projection of the edges of the rotated rectangle has as a premise that the solar panels are close to others in a structure that forms a grid. Therefore, the panels are represented by a rotated rectangle and each rectangle has four sides. Each side is two points joined together to represent a line, which is projected 1.1 times towards its ends. The projected lines of all rotated rectangles are drawn in a zeros image (Figure 7).

The determination of new contours and their classification is based on the premise that the panels have a homogeneous shape, are grouped and can be classified by texture descriptors. So, the contours are calculated from the matrix of zeros with the lines drawn. The contours are classified in different steps: first the contours with an area deviating less than 30% from the average area are selected. Second, contours that do not overlap with the detected panels are selected. Third, they are classified according to whether they belong to the panel structure or not. If they cannot be associated with the structure, they are classified using a support vector machine (see Section 2.2.3) (Figure 7).

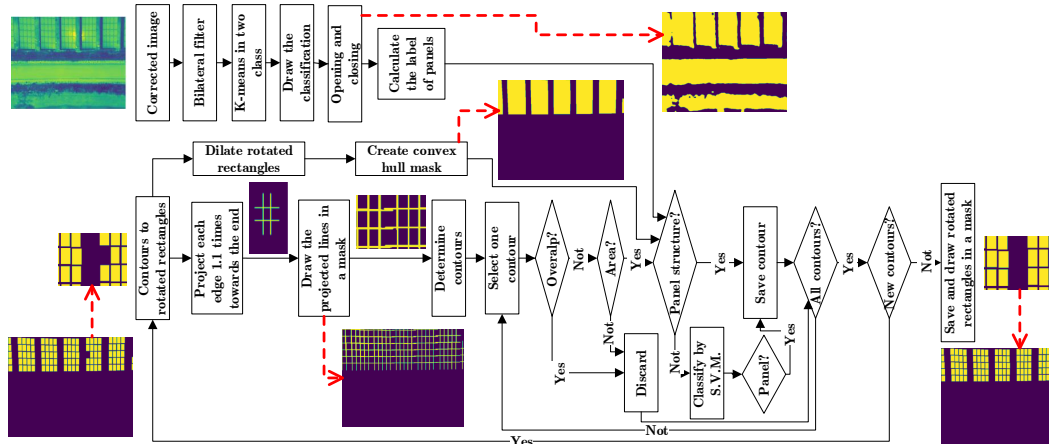


Figure 7. Projection of the edges of the rotated rectangle, determination of new contours and their classification.

To evaluate whether an outline belongs to a panel structure, the following assumptions are made: if the detected panels are close enough, they are in structures and the pixels can be classified into two classes, one of which represents the panel structures. The first premise is represented in a mask, which is created in the following way: First, all detected panels are expanded until they overlap with their nearest neighbour. Second, all panels are drawn in a mask. Third, the contours of the mask are calculated. Fourth, the convex hull is calculated for each contour. Fifth, a mask is drawn with the convex hulls. The second premise is taken to a mask with the following steps: First, a bilateral filter is applied to the corrected image. Second, the pixels are classified in two classes using K-means.

Third, a mask is drawn with the classification. Fourth, a morphological function of opening and closing is applied to eliminate the noise. Fifth, the label corresponding to the detected panels is determined. The selection takes into account the contour belonging to the convex hull mask and the k-means mask. Since undetected panels in the corners do not intersect with the entire area of the convex hull mask, then at least a 20% overlap is accepted. Because the k-means mask can have classification errors, it is acceptable for the contour to have 85% of the pixels classified as panel area.

2.3. Panel Prediction with Deep Learning

2.3.1. Detectron2

Regarding the panel prediction using deep learning, the PyTorch-based modular object detection library Detectron2 is employed. Detectron2 also has implementation of mask R-CNN and mask R-CNN have greater accuracy than those based on R-CNN, fast R-CNN, YOLO among others [45]. Furthermore, The Detectron2 library was chosen because it has better results on benchmarks compared to other popular open source mask R-CNN implementations [42]. The Mask R-CNN network is trained with thermal images with only one class: solar panels. With the support of the algorithm described in Section 2.2 and a graphical interface, all the panels present in an image are labelled in COCO format, even the panels at the edges of the image. Labeling is done in the visual interface by a user who eliminates false positives and corrects false negatives. Because Detectron2 only supports 8-bit images, a pre-treatment of the image is done and it is converted to three channels.

To accentuate the edges, a three-channel image is created as follows: first, a sigmoidal normalization of the 14-bit TIF image is applied; then the data is transformed in the range 0 to 255; the first channel has no transformation; the second channel has a bilateral filter as described in Section 2.2.2; and the third channel has a gamma correction as described in Section 2.2.2.

The detectron2 model is trained with the procedures reported for a new data set [42], the model is mask_rcnn_R_50_FPN_3x. The Mask R-CNN network is trained using 2000 cycles and a custom data loader. The custom data loader is used for data augmentation, with random changes of: 1 percent rotation, horizontal flip, contrast between 0.5 and 1.5, brightness between 0.6 and 1.5, lighting of 2, saturation between 0.5 and 1.5 and a crop function. Through previous evaluations it was determined that the prediction with the score threshold of 0.2 does not affect the false positives and allows not to exclude panels of difficult detection. Finally, the results are drawn on an image and each prediction is exported to a mask in a NumPy file [37].

2.3.2. Post-Processing

This algorithm follows the same process of Section 2.2.4 except for the following variation in the first step where the contours of the detected panels are selected. First, the predictions of the panels are drawn in masks and from these the contours are calculated and eroded to avoid overlapping. Second, before calculating the average area, the data is debugged by removing the tails of the distribution. Third, the rotation angle of the rotated rectangle is not used for the contour selection.

2.4. Evaluation

The detection efficiency of the methods is evaluated by a test data set, which is different from the training data set. The novel method based on classical techniques consists of a training part for the texture descriptors. The texture database is not part of the images selected for evaluation, so all labeled images are used as a test image. Prediction with deep learning requires training, therefore, to include all labeled images in the test the concept of cross validation is used. The images were divided into five groups, so that in each group 80% is used for training and 20% for testing, and the images selected for testing are different for all groups (Figure 8).

All panel detection steps of both methods are evaluated with precision metrics (Figure 8), the classification metrics of a single class are used, in which positive and negative values are taken into account [46]. The metrics used to evaluate the effectiveness of classification are precision, recall and F-measure [32].

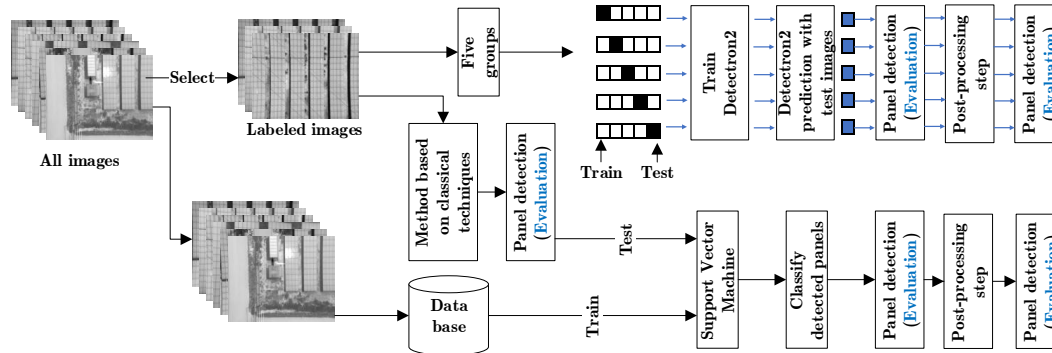


Figure 8. Origin of the Images to train and test for each method and the steps in which the prediction of panels is evaluated.

The precision represents the proportion of positive samples that were correctly classified compared to the total number of predicted positive samples [47] as indicated in Equation (1), where tp indicates the number of true positives and fp indicates the number of false positives:

$$Precision = \frac{tp}{tp + fp} \quad (1)$$

The recall of a classifier represents the correctly classified positive samples to the total number of positive samples [47] and it is estimated according to Equation (2), where fn indicates the number of false negatives:

$$Recall = \frac{tp}{tp + fn} \quad (2)$$

The main F-measure is the F_1 score which is defined as the harmonic mean of precision and recall [48]. It is estimated according to Equation (3):

$$F_1 = 2 \cdot \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

The detected panels are drawn on the image and through visual inspection the false positives are determined. We define a false positive as a selection that is not a panel or a panel that presents: center shift, associate more than one panel, or an area less than 90%. The false negatives are the undetected panels. The total number of panels is the total number of labels used for training. The value of the true positive is the total number of panels minus the false negatives.

3. Results

Regarding the panel classification described in Section 2.2.3, 440 texture descriptors are calculated and a vector of 290 texture descriptors is optimized. A database with 1555 panel vectors and 302 non-panel vectors is created by a visual classification. This database is used to train a support vector machine. The database has a classification efficiency of 91% as it was evaluated in 10-fold cross validation.

For the deep learning based method, predictions of images not used for training were made. To that end the thermal photos were divided into five groups and 80 photos were used for training and 20 photos for prediction, alternating the groups so that the prediction photos were not repeated.

The detections made by each method in each step were drawn on the original image. These images were used for visual inspection and determining the false negatives and false positives.

Figure 9 shows five cases of thermal images with complex backgrounds and panel detection with a novel method based on classic techniques with a post-processing step. The first is an image with sun reflection; the second is an image with the presence of overhead power lines with cuts close to 45 degrees with the geometry of the panels; the third an image with the presence of energy lines with cuts close to 90 degrees with the geometry of the panel; the fourth is an image with poorly defined panel edges; and the fifth presents structures like panels. In these images they show the detections made in each step of this method. Therefore, in the first step (see Section 2.2.2) the images show numerous false positives, which are reduced with the second step (see Section 2.2.3) when sorting with a support vector machine. Ending with the drawing of panels that have not been detected (see Section 2.2.4). However, due to the selection of outlines in the last step, some distorted panels (due to the distortion of the image by the camera lens) are removed from the edges.




Figure 9. Detection of panels in thermal images with a novel method based on classical techniques and a post-processing step. Different cases of true positives, false positives and false negatives: (a) Thermal image in gray scale, (b) classification by classical segmentation with classical method, (c) classification with a support vector machine and (d) classification after post-processing.

The images of Figure 9 are consistent with the data shown in Table 2. This table shows that the classical method in complex environments without machine learning has a precision value of 0.886, which would lead to dismissing this method. However, the addition of the post-processing step allows to improve the quality of the method raising the value of precision to 0.997. However, the number of panels detected does not have such a large rise as the recall value is only increased by 0.009. This is because in the post-processing step some detections are eliminated because they are distorted. These variations are reflected in the value of the F_1 score, which has an increase between the first and third step of 0.06.

Table 2. The precision, recall and F_1 score metrics for panel detection in thermal images for three steps of our novel method based on classical techniques: segmentation, classification with a support vector machine (SVM) and after post-processing.

Method	T Positives	F Positives	F Negatives	Precision	Recall	F_1 Score
Segmentation	17,537	2262	707	0.886	0.961	0.922
Segmentation + SVM	17,599	274	645	0.985	0.965	0.975
Segmentation + SVM + post-processing	17,688	60	556	0.997	0.970	0.983

Figure 10 shows the same five cases of thermal images with complex backgrounds presented in the Figure 9 and panel detection with deep learning and a post-processing step. These images show that the deep learning method leads to a greater stability in the shape of the panel, with the four sides well defined. However, this method has failures in images with power lines, poorly defined panel edges and panel-like structures. These detection failures are partially solved in the post-processing step.




Figure 10. Detection of panels in thermal images with our deep learning method and a post-processing step. Different cases of true positives, false positives and false negatives: (a) thermal image in gray scale, (b) panel detection with deep learning, (c) after post-processing.

Table 3 shows the values of the precision metrics for the test evaluations in the deep learning prediction and drawing step. The precision value shows that the deep learning method has few errors, but the recall shows the sensitivity of the method to the training data, so training with a large database is recommended. In this table, it is shown how the post-processing step affects the accuracy metrics. This is demonstrated in the change of the total data of the groups, reducing the false negatives by more than 60% that lead to an increase of the recall value of 0.032, reaching a precision value of 0.996.

Table 3. The precision, recall and F_1 score metrics for panel detection in thermal images using deep learning method, before and after post-processing.

Method	Group	T Positives	F Positives	F Negatives	Precision	Recall	F_1 Score
Deep learning	1	3400	16	138	0.995	0.961	0.978
	2	3848	6	267	0.998	0.935	0.966
	3	3117	25	199	0.992	0.940	0.965
	4	3615	28	170	0.992	0.955	0.973
	5	3342	13	148	0.996	0.958	0.976
	Total	17,322	88	922	0.995	0.949	0.972
Deep learning + post-processing	1	3468	15	70	0.996	0.980	0.988
	2	4050	6	65	0.999	0.984	0.991
	3	3246	17	70	0.995	0.979	0.987
	4	3694	17	91	0.995	0.976	0.986
	5	3443	8	47	0.998	0.987	0.992
	Total	17,901	63	343	0.996	0.981	0.989

4. Discussion

The proposed methods solve the problems related to the complex backgrounds mentioned in this article. For the new method based on classical techniques, the following points were verified: first, the correction posed in Section 2.2.1 was effective in the case of images with an atypical distribution of data due to hot spots. Second, that the procedure posed in Section 2.2 allows the accentuation of diffuse edges. Third, that the classification with support vector machine allows the elimination of panel-like structures. However, this method is affected by objects that cause the panel geometry to be lost, as well as edge distortion. In the case of the proposed method with deep learning, the process of image normalization and training with data augmentation allows to overcome the new method. However, it fails in prediction due to loss of edges, diffuse edges and loss of panel geometry. The errors presented by each of the methods were overcome with the post-processing step, in which distorted predictions were eliminated, and the location of panels was inferred by taking prior information into account.

The value of the accuracy metrics in Tables 2 and 3 for the post-processing step have a value greater than 0.97 which implies that the panel detection methods are reliable, confirmed by the precision value being greater than 0.996. Finally the value of F_1 score is similar for both methods with a value of 0.98 for all detections.

However, the reduction of false negatives by the post-processing step is greater in the case of deep learning. This is because it has a better geometry in the detection. In the new method, the greatest influence was in the reduction of false positives. Therefore the method of deep learning with the post-processing step of panels has greater feasibility of improving the number of panels detected in environments with the presence of greater amounts of anomalies.

5. Conclusions

The identification of solar panels is difficult with complex backgrounds especially when there are power lines parallel to the panel edges and when there are shadows of weeds on the panel edges. Nevertheless, the proposed methods for panel detection obtain a high precision in detecting the solar panels in these circumstances.

Two panel detection methods were evaluated on 100 thermal images from 11 drone flights at three solar plants. The first method involved image correction, image segmentation and classification of these segments using support vector machines trained with an optimized vector of texture descriptors, and a post-processing. This method obtained the following values of accuracy metrics in experiments: precision of 0.997, recall of 0.970 and F_1 score of 0.983. The second method is based on deep learning and a post-processing step, for which five groups of data were defined, in which 80 photos were used

for training and 20 for testing, so that when all the test data were added up, the following values of accuracy metrics were obtained: precision of 0.996, recall of 0.981 and F_1 score of 0.989.

By comparing the false positives of the two methods, the post-processing step was more effective for the deep learning method, reducing them by more than 60%, demonstrating that this method allows for improved panel detection. In this paper, it is demonstrated that the two panel detection methods with a post-processing step are effective in complex backgrounds.

Future work involves the correction of the lens distortions present in the thermal images, the use of different methods for the projection of panels to locate the panels that have not been detected, the optimization of the method for use in orthomosaics, the incorporation of a layer of geographic information for the location of power lines, and the combination of the panel detection with algorithms for the detection of panel failures with their correct classification.

Author Contributions: Conceptualization, J.J.V.D., M.V., D.L., S.A.O.V. and H.L.; methodology, J.J.V.D., M.V. and H.L.; software, J.J.V.D. and M.V.; validation, J.J.V.D. and M.V.; formal analysis, J.J.V.D., M.V. and H.L.; investigation, J.J.V.D. and M.V.; resources, D.L. and H.L.; writing—original draft preparation, J.J.V.D.; writing—review and editing, M.V. and H.L.; visualization, J.J.V.D.; supervision, S.A.O.V. and H.L.; project administration, H.L.; funding acquisition, H.L. All authors have read and agreed to the published version of the manuscript.

Funding: The project is co-financed by imec and received project support from Flanders Innovation & Entrepreneurship (project nr. HBC.2019.0050). The work presented in this paper has also been made possible through the COLCIENCIAS scholarship granted by the CEDAGRITOL research group. Finally, the work presented in this paper builds upon the expertise built up in the COMP4DRONES project. This project has received funding from the ECSEL Joint Undertaking (JU) under grant agreement No 826610.

Acknowledgments: This work was executed within the imec.icon project ANALYST-PV, a research project bringing together academic researchers and industry partners. The ANALYST-PV consortium aims at developing a fault diagnosis framework for PV power plants that relies on Internet of Things (IoT) sensors, AI-enabled root cause analysis and automatic image analysis.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Busu, M. Analyzing the impact of the renewable energy sources on economic growth at the EU level using an ARDL model. *Mathematics* **2020**, *8*, 1367. [[CrossRef](#)]
2. Zheng, Y.; Weng, Q. Modeling the effect of green roof systems and photovoltaic panels for building energy savings to mitigate climate change. *Remote Sens.* **2020**, *12*, 2402. [[CrossRef](#)]
3. Javadi, M.S.; Gough, M.; Lotfi, M.; Esmael Nezhad, A.; Santos, S.F.; Catalão, J.P.S. Optimal self-scheduling of home energy management system in the presence of photovoltaic power generation and batteries. *Energy* **2020**, *210*. [[CrossRef](#)]
4. Dhriyyef, M.; El Mehdi, A.; Elhitmy, M.; Elhafyani, M. Management strategy of power exchange in a building between grid, photovoltaic and batteries. *Lect. Notes Electr. Eng.* **2020**, *681*, 831–841. [[CrossRef](#)]
5. Thomas, A.; Racherla, P. Constructing statutory energy goal compliant wind and solar PV infrastructure pathways. *Renew. Energy* **2020**, *161*, 1–19. [[CrossRef](#)]
6. Wu, Z.; Hu, Y.; Wen, J.X.; Zhou, F.; Ye, X. A Review for Solar Panel Fire Accident Prevention in Large-Scale PV Applications. *IEEE Access* **2020**, *8*, 132466–132480. [[CrossRef](#)]
7. Yahyaoui, I.; Segatto, M.E.V. A practical technique for on-line monitoring of a photovoltaic plant connected to a single-phase grid. *Energy Convers. Manag.* **2017**, *132*, 198–206. [[CrossRef](#)]
8. Beránek, V.; Olšan, T.; Libra, M.; Poulek, V.; Sedláček, J.; Dang, M.Q.; Tyukhov, I.I. New monitoring system for photovoltaic power plants' management. *Energies* **2018**, *11*, 2495. [[CrossRef](#)]
9. Wang, Y.L.; Sun, J.; Xu, H.W. Research on solar panels online defect detecting method. *Appl. Mech. Mater.* **2014**, *635–637*, 938–941. [[CrossRef](#)]
10. Haider, M.; Doegar, A.; Verma, R.K. Fault identification in electrical equipment using thermal image processing. In Proceedings of the 2018 International Conference on Computing, Power and Communication Technologies (GUCON), Greater Noida, India, 28–29 September 2018; pp. 853–858. [[CrossRef](#)]

11. Phoolwani, U.K.; Sharma, T.; Singh, A.; Gawre, S.K. IoT Based Solar Panel Analysis using Thermal Imaging. In Proceedings of the 2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS), Bhopal, India, 22–23 February 2020. [\[CrossRef\]](#)
12. Chen, J.; Lin, C.; Liu, C. The efficiency and performance detection algorithm and system development for photovoltaic system through use of thermal image processing technology. *AIP Conf. Proc.* **1978**, 470088. [\[CrossRef\]](#)
13. Chawla, R.; Singal, P.; Garg, A.K. A Mamdani Fuzzy Logic System to Enhance Solar Cell Micro-Cracks Image Processing. *3D Research* **2018**, 9, 34. [\[CrossRef\]](#)
14. Sulas-Kern, D.B.; Johnston, S.; Meydbray, J. Fill Factor Loss in Fielded Photovoltaic Modules Due to Metallization Failures, Characterized by Luminescence and Thermal Imaging. In Proceedings of the 2019 IEEE 46th Photovoltaic Specialists Conference (PVSC), Chicago, IL, USA, 16–21 June 2019; pp. 2008–2012. [\[CrossRef\]](#)
15. Alsafasfeh, M.; Abdel-Qader, I.; Bazuin, B. Fault detection in photovoltaic system using SLIC and thermal images. In Proceedings of the 2017 8th International Conference on Information Technology (ICIT), Amman, Jordan, 17–18 May 2017; pp. 672–676. [\[CrossRef\]](#)
16. Menéndez, O.; Guamán, R.; Pérez, M.; Cheein, F.A. Photovoltaic modules diagnosis using artificial vision techniques for artifact minimization. *Energies* **2018**, 11, 1688. [\[CrossRef\]](#)
17. Jaffery, Z.A.; Dubey, A.K.; Irshad; Haque, A. Scheme for predictive fault diagnosis in photo-voltaic modules using thermal imaging. *Infrared Phys. Technol.* **2017**, 83, 182–187. [\[CrossRef\]](#)
18. Gao, X.; Munson, E.; Abousleman, G.P.; Si, J. Automatic solar panel recognition and defect detection using infrared imaging. In *Automatic Target Recognition XXV*; International Society for Optics and Photonics: Bellingham, WA, USA, 2015; Volume 9476, p. 94760O. [\[CrossRef\]](#)
19. Dávila-Sacoto, M.; Hernández-Callejo, L.; Alonso-Gómez, V.; Gallardo-Saavedra, S.; González, L.G. Detecting Hot Spots in Photovoltaic Panels Using Low-Cost Thermal Cameras. *Commun. Comput. Inf. Sci.* **2020**, 1152, 38–53. [\[CrossRef\]](#)
20. Henry, C.; Poudel, S.; Lee, S.W.; Jeong, H. Automatic detection system of deteriorated PV modules using drone with thermal camera. *Appl. Sci.* **2020**, 10, 3802. [\[CrossRef\]](#)
21. Lee, D.; Park, J. Development of Solar-Panel Monitoring Method Using Unmanned Aerial Vehicle and Thermal Infrared Sensor. In *IOP Conference Series: Materials Science and Engineering*; IOP Publishing: Bristol, UK, 2019; Volume 611. [\[CrossRef\]](#)
22. Lee, D.H.; Park, J.H. Developing inspection methodology of solar energy plants by thermal infrared sensor on board unmanned aerial vehicles. *Energies* **2019**, 12, 2928. [\[CrossRef\]](#)
23. Park, J.; Lee, D. Precise Inspection Method of Solar Photovoltaic Panel Using Optical and Thermal Infrared Sensor Image Taken by Drones. In *IOP Conference Series: Materials Science and Engineering*; IOP Publishing: Bristol, UK, 2019; Volume 611. [\[CrossRef\]](#)
24. Lee, S.; An, K.E.; Jeon, B.D.; Cho, K.Y.; Lee, S.J.; Seo, D. Detecting faulty solar panels based on thermal image processing. In Proceedings of the 2018 IEEE International Conference on Consumer Electronics (ICCE), Las Vegas, NV, USA, 12–14 January 2018; pp. 1–2. [\[CrossRef\]](#)
25. López-Fernández, L.; Lagüela, S.; Fernández, J.; González-Aguilera, D. Automatic evaluation of photovoltaic power stations from high-density RGB-T 3D point clouds. *Remote Sens.* **2017**, 9, 631. [\[CrossRef\]](#)
26. Alsafasfeh, M.; Abdel-Qader, I.; Bazuin, B.; Alsafasfeh, Q.; Su, W. Unsupervised fault detection and analysis for large photovoltaic systems using drones and machine vision. *Energies* **2018**, 11, 2252. [\[CrossRef\]](#)
27. Ismail, H.; Chikte, R.; Bandyopadhyay, A.; Al Jasmi, N. Autonomous detection of PV panels using a drone. In Proceedings of the ASME International Mechanical Engineering Congress and Exposition, Salt Lake City, UT, USA, 11–14 November 2019; Volume 4. [\[CrossRef\]](#)
28. Alfaro-Mejía, E.; Loaiza-Correa, H.; Franco-Mejía, E.; Hernández-Callejo, L. Segmentation of Thermography Image of Solar Cells and Panels. *Commun. Comput. Inf. Sci.* **2020**, 1152, 1–8. [\[CrossRef\]](#)
29. Greco, A.; Pironti, C.; Saggese, A.; Vento, M.; Vigilante, V. A deep learning based approach for detecting panels in photovoltaic plants. In Proceedings of the ACM International Conference Proceeding Series, Las Palmas de Gran Canaria, Spain, 7–9 January 2020. [\[CrossRef\]](#)
30. Zhu, L.; Zhao, J.; Fu, Y.; Zhang, J.; Shen, H.; Zhang, S. Deep learning algorithm for the segmentation of the interested region of an infrared thermal image. *J. Xidian Univ.* **2019**, 46, 107–114. [\[CrossRef\]](#)

31. Liao, K.C.; Lu, J.H. Using Matlab real-time image analysis for solar panel fault detection with UAV. In *Journal of Physics: Conference Series*; IOP Publishing Ltd.: Bristol, UK, 2020; Volume 1509. [CrossRef]
32. Addabbo, P.; Angrisano, A.; Bernardi, M.L.; Gagliarde, G.; Mennella, A.; Nisi, M.; Ullo, S. A UAV infrared measurement approach for defect detection in photovoltaic plants. In Proceedings of the 4th IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace), Padua, Italy, 21–23 June 2017; pp. 345–350. [CrossRef]
33. Uma, J.; Muniraj, C.; Sathya, N. Diagnosis of photovoltaic (PV) panel defects based on testing and evaluation of thermal image. *J. Test. Eval.* **2019**, *47*. [CrossRef]
34. Dhimish, M.; Alrashidi, A. Photovoltaic degradation rate affected by different weather conditions: A case study based on pv systems in the uk and australia. *Electronics* **2020**, *9*, 650. [CrossRef]
35. Libra, M.; Daneček, M.; Lešetický, J.; Poulek, V.; Sedláček, J.; Beránek, V. Monitoring of defects of a photovoltaic power plant using a drone. *Energies* **2019**, *12*, 795. [CrossRef]
36. Dji. Zenmuse XT Specs. 2020. Available online: <https://www.dji.com/zenmuse-xt/specs> (accessed on 20 September 2020).
37. Harris, C.R.; Millman, K.J.; van der Walt, S.J.; Gommers, R.; Virtanen, P.; Cournapeau, D.; Wieser, E.; Taylor, J.; Berg, S.; Smith, N.J.; et al. Array programming with NumPy. *Nature* **2020**, *585*, 357–362. [CrossRef]
38. Garrido, G.; Joshi, P. *OpenCV 3.x with Python By Example—Second Edition: Make the Most of OpenCV and Python to Build Applications for Object Recognition and Augmented Reality*, 2nd ed.; Packt Publishing: Birmingham, UK, 2018.
39. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-learn: Machine Learning in Python. *J. Mach. Learn. Res.* **2011**, *12*, 2825–2830.
40. Van Griethuysen, J.J.M.; Fedorov, A.; Parmar, C.; Hosny, A.; Aucoin, N.; Narayan, V.; Beets-Tan, R.G.H.; Fillion-Robin, J.C.; Pieper, S.; Aerts, H. Computational radiomics system to decode the radiographic phenotype. *Cancer Res.* **2017**, *77*, e104–e107. [CrossRef]
41. Jiao, Y.; Ijzura, O.M.; Zhang, L.; Shen, D.; Wang, Q. Curadiomics: A GPU-based radiomics feature extraction toolkit. *Lect. Notes Comput. Sci.* **2020**, *11991*, 44–52. [CrossRef]
42. Wu, Y.; Kirillov, A.; Massa, F.; Lo, W.Y.; Girshick, R. Detectron2. 2019. Available online: <https://github.com/facebookresearch/detectron2> (accessed on 20 September 2020).
43. Avants, B.B.; Tustison, N.J.; Stauffer, M.; Song, G.; Wu, B.; Gee, J.C. The Insight ToolKit image registration framework. *Front. Neuroinform.* **2014**, *8*, 44. [CrossRef] [PubMed]
44. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit Learn. 1.5. Stochastic Gradient Descent. 2020. Available online: <https://scikit-learn.org/stable/modules/sgd.html> (accessed on 20 September 2020).
45. Bharati, P.; Pramanik, A. Deep Learning Techniques—R-CNN to Mask R-CNN: A Survey. In *Computational Intelligence in Pattern Recognition; Advances in Intelligent Systems and Computing*; Springer: Singapore, 2020; Volume 999, pp. 657–668. [CrossRef]
46. Hoffmann, F.; Bertram, T.; Mikut, R.; Reischl, M.; Nelles, O. Benchmarking in classification and regression. *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.* **2019**, *9*, e1318. [CrossRef]
47. Tharwat, A. Classification assessment methods. *Appl. Comput. Inform.* **2018**. [CrossRef]
48. Chicco, D.; Jurman, G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genom.* **2020**, *21*, 6. [CrossRef]

Publisher’s Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Anexo E: Artículo 4

Prediction of physiological maturity of "Hass" avocado by image texture descriptors[★]

Vega D. Jhon J.^{a,1}, Orjuela, Sergio A.^a, Hernandez D. Andres I.^a and Sandoval A. Angélica P.^b

^aAntonio Nariño University, Colombia

^bTolima University, Colombia

ARTICLE INFO

Keywords:

Avocado "Hass"

Harvest index

RGB images

Texture descriptors

ABSTRACT

The "Hass" avocado tree at the time of harvest has fruits in different stages of development and visual identification of fruits with physiological maturity or suitable for harvest is not efficient. Therefore, to avoid post-harvest losses, a method to classify the fruit directly on the tree is required. This method is based on the characterization of RGB images of fruits by texture descriptors, and the optimization of a vector of texture descriptors that allow the training of a binary classifier. The texture descriptors correspond to the results of 14 texture algorithms. From the algorithms obtained a histogram was characterized with statistical operators. And of the algorithms that generate a model, the coefficients of the model are taken as the descriptor. The RGB image was transformed into a HSV image and a grey image of a channel of the HSV image was characterized with 100 texture descriptors. The support vector machine was used as a classifier and to test its accuracy classification it was evaluated by 10-fold cross-validation. Images of fruits under controlled lighting conditions in the laboratory and of fruits on the tree were acquired. These images were acquired with a homogeneous spatial resolution. We conducted a N-way analysis of variance (ANOVA) of the classification accuracy for different source data. The source data were a pre-treatment of the RGB image and different combinations of the descriptors obtained from the different channels of the HSV image. The RGB image pre-treatment tested was a contrast-limited adaptive histogram equalization. We obtained a higher classification accuracy when using the data from more channels of the HSV image. And the images in environmental conditions require the image pre-treatment. For the best optimized vector the classification efficiency for the laboratory data in classification accuracy was of 95% and the area under the ROC curve was of 0.97; for the images of fruits on the tree the classification accuracy was of 98% and the area under the ROC curve was of 0.98.

1. Introduction

Worldwide, 74% of avocado production is concentrated in the Americas, with the main producer being Mexico and Colombia in fifth place [18]. In Colombia in 2018, the main producing departments were Antioquia, Caldas and Tolima [34], this crop has a very good reputation in international markets, fulfilling high quality requirements [25]. The most commercialized cultivar is the "hass" (*Persea Americana Mill*) [6].

Avocado is a climacteric fruit that does not ripen on the tree [17], so it must be harvested during the suitable physiological maturity stage to achieve the edible characteristics of taste and firmness [41]. If it is picked too soon, it will not meet export requirements [42, 4, 32], and if it is harvested after it reaches physiological maturity it will have a low post-harvest shelf life [10].

It is very hard to visually determine the appropriate maturity stage in the 'Hass' avocado for harvesting because the fruit does not exhibit any notable external change in appearance while on the tree [7]. Furthermore, the heterogeneity of the fruit, especially Hass avocado, makes the visual diagnosis of its maturity difficult. Visual diagnosis occurs in different stages, firstly on the tree, and secondly by the exporter.

Correct visual diagnosis on the tree is important, because if the Hass avocado fruit is not picked at the optimal time, the high percentage of dry matter means that it will mature too fast [10]. Furthermore, there is the heterogeneity

[★]This document is the results of the research project funded between Tolima government and Tolima university. The agreement No 2076 was: "Development of knowledge for the generation of production and post-harvest technologies of the hass avocado in the department of tolima".

✉ jvega66@uan.edu.co (V.D.J. J.); seorjuela@uan.edu.co (O.S. A.); andres.hernandez@uan.edu.co (H.D.A. I.);
apsandovala@ut.edu.co (S.A.A. P.)

ORCID(s): 0000-0002-2165-8536 (V.D.J. J.); 0000-0002-0850-6394 (S.A.A. P.)

¹Doctoral student beneficiary of a scholarship from COLCIENCIAS call 755, this call had the support of the research group CEDAGRITOL.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors^{*,**}

Jhon Jairo Vega Díaz^{a,1}, Sergio Alejandro Orjuela Vargas^a, Andres Ignacio Hernandez Duarte^a and Angélica Piedad Sandoval Aldana^b

^aAntonio Nariño University, Colombia

^bTolima University, Colombia

ARTICLE INFO

Keywords:

Avocado "Hass"
Physiological maturity
RGB images
Texture descriptors
Support vector machine

ABSTRACT

At the time of harvest, the "Hass" avocado tree presents fruit at different stages of maturity and it is not possible to visually identify the appropriate physiological maturity for harvesting. Therefore, to avoid losses after harvest, a method is required to classify whether the fruit is physiologically mature. We propose a new method to classify fruit images with an optimized vector of texture descriptors. The evaluation is done in the laboratory and with the fruit on the tree. This method uses uncompressed RGB images with homogeneous spatial resolution. The method have five steps. First, image acquisition; second, Image fruit segmentation; third, image pre-treatment; fourth, calculation of a set of texture descriptors; fifth, optimization of a vector of texture descriptors. The image pre-treatment are a contrast-limited adaptive histogram equalization (CLAHE) and an image conversion to HSV color space. A support vector machine is used as a classifier and its is evaluated in cross validation. This research evaluates the classification accuracy for the choice of using or not using the CLAHE in combination with any of the three channels of the HSV image. Image pre-treatment with CLAHE improves the classification of fruit images in the tree and the highest accuracy is achieved with descriptors of all HSV image channels. The best vector for laboratory images have an classification accuracy value of 95% and the area under the receiver operating characteristic curve of 0.97; for the images of the fruit on the tree the classification accuracy is of 98% and the area under the receiver operating characteristic curve is of 0.98. The proposed method is effective to classify if an avocado fruit has physiological maturity.

1. Introduction

The world demand of avocado has increased in the last years and the cultivar with greater commercialization is the "Hass" (*Persea Americana Mill*) [6]. The biggest production is in the American continent, and Colombia is the fifth worldwide producer [17], and the department of Tolima is the biggest national producer [33]. This crop has been encouraged for export and one of the requirements is to guarantee an adequate maturity of the fruit [24].

There are two stages of maturation, one is the physiological maturity and the other is the consumption maturity. Physiological maturity is defined as: the stage of development when an avocado fruit will continue in ontogeny even after it has been detached from the tree [25]. Avocado does not ripen for consumption on the tree [16], therefore, to achieve desired characteristics of taste and firmness [39] it must be harvested after physiological maturity. If the fruit is harvested before physiological maturity it does not meet export requirements [40, 4, 31], but if it is left on the tree for a long time it will have a low post harvest shelf life [9].

The identification of the optimal time of harvest is made difficult by the heterogeneity of fruit ripening in the tree. A major cause of this heterogeneity is a long period of flowering: in Colombia the period is four months [16] and in the subtropical zone it is one month [1]. Heterogeneity in the physiological maturity leads to heterogeneity of the fruit's useful life [18] and this is called a "chess board" [37].

*This document is the results of the research project funded between the government of Tolima and Universidad del Tolima [agreement No. 2076] entitled "Knowledge development for the generation of production and post-harvest technologies for 'Hass' avocado in the Tolima region."

**The proposed new method is an integral part of a patent application filed with the Colombian Superintendence of Industry and Commerce.

✉ jvega66@uan.edu.co (J.J.V. Díaz); seorjuela@uan.edu.co (S.A.O. Vargas); andres.hernandez@uan.edu.co (A.I.H. Duarte); apsandovala@ut.edu.co (A.P.S. Aldana)

ORCID(s): 0000-0002-2165-8536 (J.J.V. Díaz); 0000-0001-9989-5331 (S.A.O. Vargas); 0000-0002-0850-6394 (A.P.S. Aldana)

¹PhD student beneficiary of a scholarship from COLCIENCIAS call 755, this call was supported by the research group CEDAGRITOL.

16 The fruit of "Hass" avocado in its process of maturation in the tree does not present visual changes that allow
17 differentiating the optimal moment of harvest [7], so, is necessary alternatives [11]. One alternative are destructive
18 techniques with analytical methods to determine the concentration of oil or dry matter [29]. But, with these methods
19 only a statistical estimation of the maturity of the fruit in a tree would be reached.

20 When a general harvest is made, not all the fruit have the required maturity for export. Then, the reduction of
21 income is assumed by the farmer. Therefore, a solution is required to identify the optimal time to harvest each fruit and
22 thus make a selective harvest. The optimal time is when the fruit has physiological maturity. This type of technology
23 must be low cost and easy to use by a picker.

24 The best approach to determining physiological maturity of the "Hass" avocado for export, involves using non-
25 destructive techniques, based in visual information. The visual changes in the skin of avocado in its ripening process
26 are due to variations in the content of lignin, chlorophylls and phenolic compounds [32]. The measurement of these
27 is done with optical microscope, Confocal Laser Scanning Microscopy [15], colorimeter [39], spectrometer[45], RGB
28 images [5] and hyperspectral images [44].

29 The use of RGB images is a potentially superior method for determining the best time to harvest [38] because it
30 is non-destructive, and therefore faster and less expensive, and used on unharvested fruit. To solve it, we focus on a
31 new method of classification of physiological maturity using texture techniques [8]. The texture patterns of an image
32 characterize the subtleties of an image with invariance in rotation and illumination. Therefore, the aim of this research
33 is to determine the physiological maturity of the "Hass" avocado using image texture pattern classification, even if the
34 fruit is still on the tree.

35 Visual characteristics are measured with texture descriptors and physiological maturity with dry matter content.
36 According to reports of variation fruit brightness and color, we apply a image pre-treatment and determine textural
37 descriptors from grayscale images in a color space [27], the color space is the HSV color space. And with support
38 vector machines we optimize a vector of texture descriptors to perform the binary classification of the images [42, 28].
39 The new proposed method is evaluated initially with photos acquired in the laboratory and later with photographs of
40 the fruit on the tree.

41 1.1. Related work

42 In a recent review by Li, Lecourt, & Bishop [27] on non-destructive assessment of fruit maturity to define opti-
43 mal harvest time they suggest a overall workflow. This workflow consists of the correlation between data from
44 non-destructive methods, maturation traits and environmental factors. The related work can be divided into three:
45 pre-harvest, harvest and post-harvest.

46 In pre-harvest evaluations, measurements of the fruit on the tree are made. Alvarez-Bravo (2017) [2] measure
47 changes in fruit roughness with RGB images, finding that this varies with fruit development and temperature, however,
48 this research do not predict the physiological maturity of the fruit. Rodriguez (2018) [39] present a model to predict
49 the time of harvest in which data of the appearance of the fruit are included, but, it requires marks from flowering.
50 And Ncama (2018) [35] predict the dry matter content with spectrometry, but, it requires contact with the fruit and a
51 specialized equipment.

52 In the evaluations with recently harvested fruit it is sought to predict the percentage of dry matter of the fruit with
53 spectrometer [45, 12, 43], or hyperspectral images [44, 13]. Achieving efficiencies above 95%. These techniques
54 predict the physiological maturity of the fruit, but require expensive calibrated equipment.

55 Post-harvest measurements show that avocado skin changes its color and texture over time [22]. These measure-
56 ments are made with a microscope [15] and RGB images [5, 14]. However, color variations are not so evident in
57 pre-harvest, since it is not possible to predict the maturity of a fruit only with the data of a colorimeter[39, 44]. There-
58 fore, color changes do not identify the physiological maturity of the avocado.

59 The characterization of avocado skin texture from RGB images is done in pre-harvest and post-harvest. In pre-
60 harvest, photos taken with a stereoscopic microscope are used, and in a geographic information system a "Spatial
61 Analyst" is used to determine the percentage of surface with a slope greater than 20% [2]. Post-harvest photos are
62 characterized by laurability, fractal dimension, entropy [15], and Gray Level Co-occurrence Matrix [5].

63 The proposed method has the following advantages over related methods:

- 64 • It can be adapted to different climates.
- 65 • This does not require monitoring of fruit development.
- 66 • It does not require contact with the fruit.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

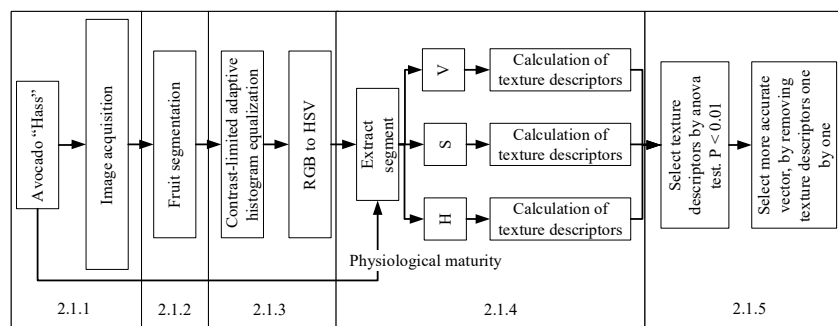


Figure 1: New avocado classification method using texture descriptors

- 67 • This does not require expensive and highly calibrated equipment.
- 68 • It can be used by a picker.

69 2. Material and methods

70 The municipality of Fresno is selected because it has the largest planted area with avocados in Tolima department
 71 [33]. The fruit orchard selected is located at the following coordinates: 5°08'21.6"N 75°06'22.5"W. Data acquisition
 72 and laboratory analyses are performed at the Post-Harvest and Quality Laboratory of the University of Tolima (Ibagué,
 73 Colombia). We harvested fruit between December 2018 and January 2020, in all development stages.

74 We divided the research into two phases. Firstly, we determine the fruit maturity classification by processing
 75 images under controlled conditions. Secondly we conduct a field test to confirm the effectiveness under uncontrolled
 76 conditions. However, methods are similar, so this section is divided into three parts: new avocado classification method
 77 using texture descriptors, destructive quantification of dry matter and model evaluation. The method is implemented
 78 using python and matlab software.

79 2.1. New avocado classification method using texture descriptors

80 The proposed method has five steps: image acquisition (Section 2.1.1), image fruit segmentation (Section 2.1.2),
 81 image pre-treatment (Section 2.1.3), calculation of texture descriptors (Section 2.1.4) and vector optimization (Section
 82 2.1.5) (Figure 1).

83 2.1.1. Image acquisition

84 One of the advantages of this method is the use of a camera with a Bayer sensor, this sensor is used in consumer
 85 cameras, which acquires visible images in RGB format. However, to minimize the memory space used by the image,
 86 data compression is applied, with the loss of image subtleties, so one of the requirements of the method is to use
 87 uncompressed images. To avoid compression of the data, we acquire the images in raw format and took them to an
 88 RGB color space with an uncompressed format, in this research the tiff format is used. We use a compact camera
 89 (Power Shot A2600, Canon U.S.A., Inc.) with CHDK software [49] to achieve the RAW image and remote control.

90 The details in the image of an object vary according to its spatial resolution, therefore, to ensure that the method
 91 is effective one of the requirements is that the images have homogeneous spatial resolution. For this research, this
 92 parameter is guaranteed with a homogeneous distance between the camera and the fruit, with an assembly for the
 93 acquisition of the photos in the laboratory and another in the field (Figure 2).

94 For the laboratory a controlled lighting space is developed [20]. The lighting space is a 35 x 35 cm cube, covered
 95 with a Lee Quarter White Diffusion filter [26] and illuminated with four 300 w halogen lamps. The camera is on the
 96 upper part of the controlled lighting space (Figure 2.a). For the fruit on the tree, we adapt a selfie stick with a guide to
 97 make contact with the fruit and guarantee a homogeneous distance between the camera and the fruit (Figure 2.b).

98 For the laboratory images, these are acquired the same day of the harvest, with shots of both sides of the fruit.
 99 For images of fruit on the tree, 2, 3 or 4 shots are taken of the same fruit at different angles and in different lighting
 100 directions. We associate each fruit and its images with a code, which is used for traceability.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors




Figure 2: Assemblies for image acquisition. a) Laboratory. b) Field




Figure 3: Fruit segmentation of images acquired from the same fruit. a) Laboratory. b) Field

2.1.2. Image fruit segmentation

We make a different fruit segmentation by images acquired in laboratory conditions and with the fruit on the tree. In the case of controlled conditions, fruit segmentation is done with python software (edition 3.6), using an OpenCV library [19]. To create the cutting mask we use the green leaf index (GLI) [23] (Equation No. 1), we cut the image with values higher than 0.01 and we segment with the ellipse function (Figure 3.a). In the case of images of fruit on the tree the segmentation is done manually with Microsoft Photos (Figure. 3.b).

$$GLI = \frac{(2 * G) - R - B}{(2 * G) + R + B} \quad (1)$$

Where, GLI : green leaf index, R : Red channel, G : Green channel and B : Blue channel.

2.1.3. Image pre-treatment

The proposed method involves a pre-treatment of the image, it is a contrast-limited adaptive histogram equalization (CLAHE) (the Matlab function `adaphisteq`). Pre-treatment is used on segmented RGB images with the procedure proposed in Matlab: "First transform the RGB image into the $L^*a^*b^*$ color space. Then, Scale values to the range expected by the `adaphisteq` function, [0 1]. After, Perform CLAHE on the L channel and Scale the result to get back to the range used by the $L^*a^*b^*$ color space. Finally, Convert the resulting image back into the RGB color space" [30]. After CLAHE the fruit image is transformed into an HSV color space.

Table 1

Texture descriptors

Algorithm	Texture descriptor
Sum and Difference Histograms	Energy, entropy, contrast, homogeneity and correlation
Co-occurrence matrix	Energy, entropy, contrast, homogeneity and correlation
Gray Level Run Length Matrix (GLRLM)	Short Run Emphasis (SRE), Long Run Emphasis (LRE), Gray-Level Nonuniformity (GLN), Run Length Nonuniformity (RLN), Run Percentage (RP), Low Gray-Level Run Emphasis (LGRE), High Gray-Level Run Emphasis (HGRE), Short Run Low Gray-Level Emphasis (SRLGE), Short Run High Gray-Level Emphasis (SRHGE), Long Run Low Gray-Level Emphasis (LRLGE) and Long Run High Gray-Level Emphasis (LRHGE)
Local Binary Pattern (LBP)	Mean, median, standard deviation, skewness, kurtosis and entropy
Law's texture measures	Mean, median, standard deviation, skewness, kurtosis and entropy
Eigenfilter	Mean, median, standard deviation, skewness, kurtosis and entropy
Gabor filter	Mean, median, standard deviation, skewness, kurtosis and entropy
The gaussian pyramid	Mean, median, standard deviation, skewness, kurtosis and entropy
The steerable pyramid	Mean, median, standard deviation, skewness, kurtosis and entropy
Wavelet decomposition	Mean, median, standard deviation, skewness, kurtosis and entropy
The power spectrum technique	Mean, median, standard deviation, skewness, kurtosis, entropy and ten coefficients
The Wigner distribution	Mean, median, standard deviation, skewness, kurtosis and entropy
Autoregressive models	Eight coefficients
Gaussian Markov Random Field	Seven coefficients

2.1.4. Calculation of texture descriptors

With the Matlab software [30], we extract a central frame with 600 x 600 pixels from the fruit segment of the image in the HSV color space. And we use all the channels to calculate the texture descriptors in table 1. We calculate 100 texture descriptors for each channel in order to find the set of vectors that allow the fruit to be sorted at a specific maturity level. To do this, we label each segment and vector with zero for images of fruit without physiological maturity and one for images of fruit with physiological maturity.

Texture descriptors are values extracted from an algorithm that characterizes the subtleties of an image. The algorithms used are divided into three groups: algorithms based on statistics, algorithms based on signal processing and algorithms based on image modeling. In the first group, the following techniques are used: sum and difference histograms, co-occurrence matrix, gray level run length matrix (GLRLM) and local binary pattern (LBP). In the second group, the following techniques are used: laws' texture measures, eigenfilter, gabor filter, the gaussian pyramid and wavelet decomposition. In the third group the following techniques are used: autoregressive models and gaussian markov random field [36].

The data processed from the textural patterns are the following: the data obtained by statistical operators, histograms and model vectors. Histograms are characterized by the first four statistical moments (mean, median, skewness and kurtosis), standard deviation and entropy. The vectors of the models are treated as a vector and each coefficient as data (Table 1).

A reference value for the dry matter content is used to classify whether the images come from a physiologically mature fruit or not. The reference dry matter content is 23.5 g kg⁻¹ [10]. However, the dry matter content among avocado samples is heterogeneous, because the fruit inside has different levels of maturity [41, 21]. Therefore, we select the fruit in which all their samples have values below or above the reference value.

2.1.5. Vector optimization

A feature selection [21] is made to determine which vector allows the best classification, this is implemented with the matlab software. Optimization is done in two steps: an elimination of the descriptors that allow less separability and a one-to-one evaluation by elimination. First, each texture descriptor is evaluated with anova test, and we select only if it has a probability value lower than 0.01. Second, with selected texture descriptors, we select the most efficient vector with a process of elimination using a support vector machine in the cross validation method. The elimination process takes the selected vector and removes one by one the texture descriptors and selects the vector with higher

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

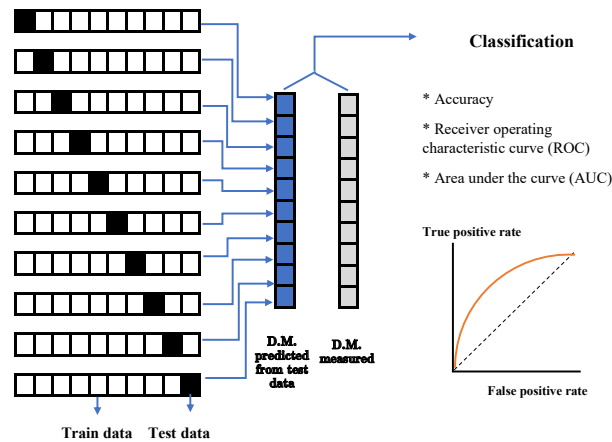


Figure 4: Cross validation with ten folds

143 classification accuracy. The classification models are evaluated in all cases with the 10-fold cross-validation method
 144 [48]. The data were divided into 10 training and testing combinations, and only the testing data are used for the model
 145 prediction.

146 2.2. Destructive quantification of dry matter

147 The physiological maturity of the fruit is related to its dry matter content, and the most accurate method is destruc-
 148 tive with oven drying. Therefore, the dry matter (D.M.) of a fruit sample is determined by the AOAC [3] method
 149 925.45. The laboratory analysis is performed after the fruit is harvested, it is transported in polyethylene coolers at
 150 10°C and four pulp samples are extracted from each fruit. The samples, of approximately 5 g, are dried at 105°C in an
 151 oven, for 24 hours, until they reach a constant weight. The difference between the initial (W_0) and final weight (W_1)
 152 is used to calculate the dry matter percentage. Calculations are made using equation No. 2. The dry matter content of
 153 the fruit is the result of the arithmetic mean of the dry matter content of at least three fruit samples.

$$154 \quad D.M. = \left(\frac{W_0 - W_1}{W_0} \right) 100 \quad (2)$$

154 Where: $D.M.$: Dry matter, W_0 : Initial weight, W_1 : final weight

155 2.3. Method evaluation

156 Texture descriptor vectors are evaluated by ten-fold cross-validation. This is characterized by evaluating only the
 157 predictions of the vector support machine trained with the test data and the results are: the accuracy, the receiver
 158 operating characteristic curve (ROC) and the area under the curve (AUC). [34] (Figure 4). This is implemented with
 159 the Matlab software

160 In this research different data sources are evaluated for the optimization of the texture descriptor vector. This
 161 evaluation is to determine which is the data source with the highest classification accuracy. Variations in the source
 162 data result from the choice of using or not using the CLAHE in combination with any of the three channels of the
 163 HSV image. In total fourteen source data with unique combinations are evaluated. To avoid statistical bias when
 164 comparing the classification accuracy of the different data sources, one hundred evaluations are performed for each
 165 vector, calculating its mean and standard deviation. To test if each of the factors evaluated contributes significantly to
 166 the classification accuracy a 4-way analysis of variance (ANOVA) is performed. The value to perform the analysis is
 167 the average of one hundred repetitions of the classification accuracy.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

Table 2

Classification accuracy in one hundred repetitions according to the data source used for images acquired in the laboratory. H: Hue channel, S: Saturation channel, V: Value channel, CLAHE: contrast-limited adaptive histogram equalization, Mean: accuracy mean of 100 repetitions, Std: standard deviation of 100 repetitions, Vector: number of texture descriptors selected in the optimized vector.

H	S	V	CLAHE	Mean	Std	Vector
Yes	Not	Not	Not	91.90	0.17	35
Not	Yes	Not	Not	91.84	0.13	32
Not	Not	Yes	Not	92.91	0.16	40
Yes	Not	Not	Yes	92.28	0.12	28
Not	Yes	Not	Yes	91.74	0.14	25
Not	Not	Yes	Yes	91.72	0.17	46
Yes	Yes	Not	Yes	94.33	0.10	32
Yes	Not	Yes	Yes	94.32	0.09	34
Not	Yes	Yes	Yes	93.79	0.11	48
Yes	Yes	Not	Not	94.53	0.12	42
Yes	Not	Yes	Not	94.58	0.10	22
Not	Yes	Yes	Not	94.23	0.11	41
Yes	Yes	Yes	Not	94.89	0.17	74
Yes	Yes	Yes	Yes	94.70	0.06	24

Table 3

4-way analysis of variance of classification accuracy for different source laboratory data

Source	Sum Sq.	Mean Sq.	F	Prob>F
H	11.41	11.405	138.183	0.001
S	8.14	8.136	98.570	0.002
V	10.48	10.484	127.024	0.001
CLAHE	0.29	0.290	3.512	0.158
H*S	0.82	0.824	9.981	0.051
H*V	1.60	1.603	19.427	0.022
H*CLAHE	0.13	0.128	1.556	0.301
S*V	1.87	1.867	22.620	0.018
S*CLAHE	0.00	0.004	0.054	0.832
V*CLAHE	0.20	0.202	2.441	0.216
Error	0.25	0.082538197	∅	∅
Total	21.28	∅	∅	∅

3. Results

The proposed new method is evaluated first with the fruit in controlled conditions and then with the fruit on the tree, therefore, the results of these two scenarios are presented. And finally an analysis of the precision metrics for the most efficient data source in both scenarios is performed.

3.1. Images with controlled illumination at laboratory

This research phase uses information from 664 fruit, with a range of dry matter between 9.75 g kg⁻¹ D.M. and 47.26 g kg⁻¹ D.M.. Data from 32 fruit are discarded because it does not have an absolute value of maturity between samples. Therefore, we use data from 632 fruit in 1257 images. The classification accuracy with different origin and different pre-treatment images are showed in Table No 2, and the 4-way analysis of variance (ANOVA) with this data is showed in Table No 3.

Table No 2 shows the higher accuracy as more channels are used and the higher accuracy is obtained with the use of three channels. This is corroborated in Table No 3 which shows that the use of each channel presents a significant difference with a probability value lower than 0.01. On the other hand, the CLAHE in Table No 3 shows a probability value upper at significance level, so this image pre-treatment decrease the classification accuracy.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

Table 4

Classification accuracy in one hundred repetitions according to the data source used for images of fruit on the tree. H: Hue channel, S: Saturation channel, V: Value channel, CLAHE: contrast-limited adaptive histogram equalization, Mean: accuracy mean of 100 repetitions, Std: standard deviation of 100 repetitions, Vector: number of texture descriptors selected in the optimized vector.

H	S	V	CLAHE	Mean	Std	Vector
Yes	Not	Not	Not	95.54	0.17	9
Not	Yes	Not	Not	96.23	0.17	9
Not	Not	Yes	Not	96.00	0.20	7
Yes	Not	Not	Yes	95.59	0.39	28
Not	Yes	Not	Yes	96.46	0.14	5
Not	Not	Yes	Yes	96.68	0.18	18
Yes	Yes	Not	Yes	98.02	0.21	23
Yes	Not	Yes	Yes	96.86	0.26	28
Not	Yes	Yes	Yes	96.81	0.23	18
Yes	Yes	Not	Not	96.14	0.32	21
Yes	Not	Yes	Not	96.28	0.33	32
Not	Yes	Yes	Not	95.55	0.22	9
Yes	Yes	Yes	Not	96.26	0.40	32
Yes	Yes	Yes	Yes	98.49	0.17	32

Table 5

4-way analysis of variance of classification accuracy for different source data for images of fruit on the tree

Source	Sum Sq.	Mean Sq.	F	Prob>F
H	0.46	0.462	3.405	0.162
S	0.91	0.915	6.738	0.081
V	0.35	0.349	2.574	0.207
CLAHE	1.98	1.975	14.552	0.032
H*S	0.47	0.468	3.444	0.160
H*V	0.11	0.106	0.784	0.441
H*CLAHE	0.51	0.510	3.760	0.148
S*V	0.25	0.248	1.830	0.269
S*CLAHE	1.20	1.200	8.844	0.059
V*CLAHE	0.52	0.525	3.865	0.144
Error	0.41	0.136	□	□
Total	9.73	□	□	□

3.2. Images of fruit on the tree

This research phase uses information from 173 fruit, with a range of dry matter between 12.63 g kg⁻¹ D.M. and 41.69 g kg⁻¹ D.M.. Data from 16 fruit are discarded because it does not have an absolute value of maturity between samples. Therefore, we use data from 157 fruit in 454 images. The classification accuracy with different origin and different pre-treatment images are showed in Table No 4, and the 4-way analysis of variance (ANOVA) with this data is showed in Table No 5.

Table No 4 shows that the accuracy of all treatments is greater than 95%, with a tendency to increase the accuracy with a greater number of channels. However, in Table No 5 shows that the addition of channels is not significant, in contrast, the pre-treatment of the image is significant with a probability value of less than 0.05. So, this image pre-treatment increase the classification accuracy.

3.3. Optimized vectors with best classification accuracy

Based on table No 2, for the images with controlled illumination at laboratory, we select the vector optimized from all channels of the HSV image without CLAHE. This vector with 74 components is optimized from 300 texture descriptors. Based on table No 4, for Images of fruit on the tree, we select the vector optimized from all channels of the HSV image with CLAHE. This vector with 32 components is optimized from 300 texture descriptors.

Trained the support vector machine with the selected vector and when making the prediction in cross validation one

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

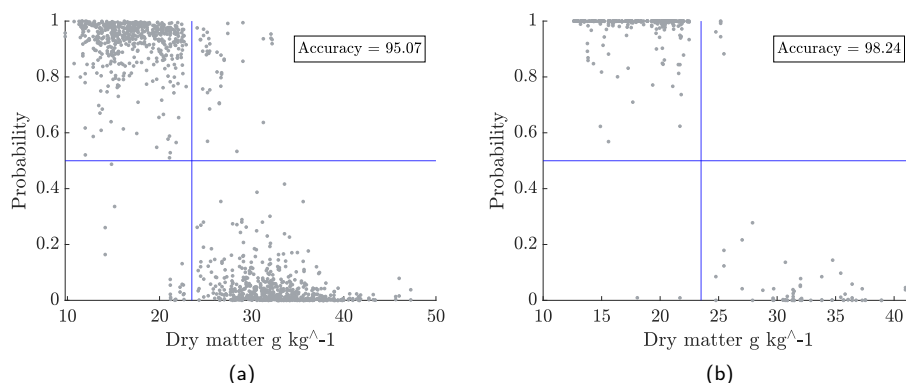


Figure 5: Probability that the image comes from an immature fruit in relation to the dry matter content of the fruit. a) Images acquired in the laboratory. b) Images of fruit on the tree. The vertical blue line indicates the physiological maturity of the fruit (23,5 g kg⁻¹ D.M.), the horizontal blue line indicates the percentage of probability to classify if a fruit is immature (>0.5) or mature (<0.5).




Figure 6: Receiver operating characteristic curve (ROC) and area under the curve (AUC) value for a support vector machine trained with the vectors selected

198 of the data is the probability that the image belongs to a class. In this case the probability that the image comes from an
 199 immature fruit is presented. Figure 4 shows this probability in relation to the dry matter content of the photographed
 200 fruit, for both scenarios. This figure shows that the range with the greatest difficulty in classifying the physiological
 201 maturity of the fruit is three percent of dry matter before and after the reference value (23.5 g kg⁻¹ D.M.).

202 Figure No 5 presents the classification efficiency for the vectors selected. The classification efficiency for the
 203 laboratory data is represented by the area under the curve of the blue line, this corresponds to 0.97. The classification
 204 efficiency for Images of fruit on the tree is represented by the area under the curve of the red line, this corresponds
 205 to 0.98. In both cases, the data shows a trend opposite to a random classification and that approaches to the perfect
 206 classification trend.

207 4. Discussion

208 Bernal (2014) and Cerdas (2014) report that visual classification of fruit maturity level is not an efficient method.
 209 The difficulty for avocado classification by visual information is broken by a combination with a vector of some textural
 210 descriptors very specific for the data origin. In addition, we checked the efficiency of a support vector machine for
 211 binary classification reported by Brereton (2010).

212 In this research, we found a relation between texture features of avocado fruit skin and the maturity level of the fruit
 213 as reported by Espinosa-Velázquez (2016). Moreover, we can measure this feature with textural descriptors of an image

of a fruit as Li (2018) reported and in concordance with the data, our new method is feasible for the classification of physiological maturity of avocado. However, the classification vector is specific to a region and it needs parameterized with regional data because the color data of fruit aren't being similar between regions, [39] the avocado skin roughness as a function of temperature [2], and the acquired data are influenced by the geographical region [46] and the season between years [47], for that independent vectors are suggested.

The optimized vector data has a higher classification accuracy with data from all channels of the HSV image. This is because the H channel contains texture information, the S channel contains brightness information, and the V channel contains color information. And texture descriptors characterize the subtle variations of avocado fruit skin in those components. In the same way, to characterize the fruit through images a contrast-limited adaptive histogram equalization is used to correct lighting problems. However, when this pre-treatment is performed on images with controlled lighting, important subtleties of the image are lost and this procedure is not recommended for laboratory conditions.

It should be noted that for images of fruit on the tree, the saturation channel has the greatest significance in the accuracy of classification. This is consistent with the pickers' empirical use of brightness as an indicator of the fruit's physiological maturity, except that this picker classification is not accurate. Finally, it is observed that the greatest error in classification occurs with fruit close to the reference value of dry matter, which must be taken into account for the implementation of the method.

5. Conclusions

A novel method is tested to classify the physiological maturity of "Hass" avocado using texture descriptors. The algorithms used are invariant to rotation and illumination so we can use in laboratory or that while the fruit is still on the tree. This method can be implemented with compact cameras with a Bayer sensor, however it requires images without compression and with a homogeneous spatial resolution.

To be used with images of fruit on the tree, it is required that the image with the segmented fruit has an image pre-treatment with an adaptive histogram equalization limited by contrast (CLAHE), and then a central segment of the image representing the avocado skin is used. This segment is transformed from the RGB color space to HSV. To obtain the highest classification accuracy, texture descriptors are calculated for each channel of the HSV image. The calculated texture descriptors are used to optimise a vector with the highest classification accuracy. For images acquired in the laboratory, it is recommended not to use the image pre-treatment with CLAHE.

By training a vector support machine with the optimized vector of the selected data source, and evaluating the physiological maturity prediction in cross validation the precision metrics values for the case of photos acquired in the laboratory are: 94.89% for the average precision in 100 repetitions and 0.97 for the area under the receiver operating characteristic curve. In the case of photos of fruit on the tree, the values are: 98.49% for the average precision in 100 repetitions and 0.98 for the area under the receiver operating characteristic curve.

The next steps are the evaluation of other texture descriptors, other optimization methods and other classifiers. As well as the development of a prototype for use by agricultural workers.

CRedit authorship contribution statement

Jhon Jairo Vega Díaz: Conceptualization, methodology, research, software, formal analysis and writing original draft. **Sergio Alejandro Orjuela Vargas:** Project leader, conceptualization, methodology, software, formal analysis and writing original draft. **Andres Ignacio Hernandez Duarte:** Project leader, conceptualization, methodology, formal analysis and writing original draft. **Angélica Piedad Sandoval Aldana:** Resources, data acquisition.

References

- [1] Alcaraz Arco, M.L., 2009. Biología reproductiva del aguacate (*Persea americana* Mill.). Implicaciones para optimización del cuajado. Ph.D. thesis. Universidad de Malaga. URL: http://www.avocadosource.com/international/spain_papers/AlcarazML2009b.pdf.
- [2] Alvarez bravo, A., Salazar-Garcia, S., 2017. Las condiciones ambientales determinan la rugosidad de la piel del fruto de aguacate 'Hass'. *Revista Mexicana de Ciencias Agrícolas* 8, 4063. doi:10.29312/remexca.v0i19.673.
- [3] AOAC International., P., Cunniff, P., 1995. Official methods of analysis of AOAC international. 16th ed. ed., The Association, Washington DC. URL: <https://www.worldcat.org/title/official-methods-of-analysis-of-aoac-international/oclc/421897987>.
- [4] Arpaia, M.L., Mitchell, F.G., Katz, P.M., Mayer, G., 1987. Susceptibility of avocado fruit to mechanical damage as influenced by variety, maturity and stage of ripeness. *South African Avocado Growers Association Yearbook* 10, 149–151.

Prediction of physiological maturity of "Hass" avocado by image texture descriptors

- 263 [5] Arzate-Vázquez, I., Chanona-Pérez, J.J., de Perea-Flores, M.J., Calderón-Domínguez, G., Moreno-Armendáriz, M.A., Calvo, H., Godoy-
264 Calderón, S., Quevedo, R., Gutiérrez-López, G., 2011. Image Processing Applied to Classification of Avocado Variety Hass (Persea americana
265 Mill.) During the Ripening Process. *Food and Bioprocess Technology* 4. doi:10.1007/s11947-011-0595-6.
- 266 [6] Astudillo-Ordóñez, C.E., Rodríguez, P., 2018. Parámetros fisicoquímicos del aguacate *Persea americana* Mill. cv. Hass (Lauraceae) producido
267 en Antioquia (Colombia) para exportación. *Corpoica Ciencia y Tecnología Agropecuaria* 19, 383–392.
- 268 [7] Bernal, J., Díaz, C., Osorio, C., Tamayo, A., Osorio, W., 2014. Actualización tecnológica y buenas prácticas agrícolas (BPA) en el cultivo de
269 aguacate. Corporación Colombiana de Investigación Agropecuaria, Medellín.
- 270 [8] Bhargava, A., Bansal, A., 2018. Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University -*
271 *Computer and Information Sciences* doi:10.1016/j.jksuci.2018.06.002.
- 272 [9] Burdon, J., Lallu, N., Haynes, G., Francis, K., Patel, M., Laurie, T., Hardy, J., 2015. Relationship between dry matter and ripening time in
273 "hass" avocado, in: *Acta Horticulturae*, pp. 291–296.
- 274 [10] Carvalho, C., Velásquez, M., Van Rooyen, Z., 2014. Determination of the minimum dry matter index for the optimum harvest of "Hass"
275 avocado fruits in Colombia | Determinación del índice mínimo de materia seca para la óptima cosecha del aguacate "Hass" en Colombia.
276 *Agronomía Colombiana* 32. doi:10.15446/agron.colomb.v32n3.46031.
- 277 [11] Cerdas Araya, M., Montero Calderón, M., Somarribas Jones, O., 2014. Verificación del contenido de materia seca como indicador de cosecha
278 para aguacate (*Persea americana*) Cultivar Hass en zona intermedia de producción de Los Santos, Costa Rica. *Agronomía Costarricense* 38,
279 207–214. URL: <https://revistas.ucr.ac.cr/index.php/agrocost/article/view/15205>.
- 280 [12] Clark, C.J., McGlone, V.A., Requejo, C., White, A., Woolf, A.B., 2003. Dry matter determination in "Hass" avocado by NIR spectroscopy.
281 *Postharvest Biology and Technology* 29. doi:10.1016/S0925-5214(03)00046-2.
- 282 [13] Denis Girod, M., Landry, J.A., Doyon, G., Osuna García, J.A., 2008. Predicting Maturity of Hass Avocado Using Hyperspectral Imagery.
283 *Caribbean Food Crops Society* 44 (2), 27. URL: http://www.ars-grin.gov/may/documents/CFCS%7B_%7D2008.pdf.
- 284 [14] Edgar Roa Guerrero, Gustavo Meneses Benavides, 2014. Automated system for classifying Hass avocados based on image processing tech-
285 niques, in: 2014 IEEE Colombian Conference on Communications and Computing (COLCOM), IEEE. pp. 1–6. doi:10.1109/ColComCon.
286 2014.6860414.
- 287 [15] Espinosa-Velázquez, Dorantes-Alvarez, L., Gutiérrez-López, G.F., García-Armenta, E., Sánchez-Segura, L., Perea-Flores, M.J., Ceballos-
288 Reyes, G.M., Ortíz Moreno, A., 2016. Morpho-structural description of unripe and ripe avocado pericarp (*Persea americana* Mill var. *drymi-*
289 *folia*) | Descripción morfo-estructural del pericarpio del aguacate (*Persea americana* Mill var. *drymifolia*) inmaduro y maduro. *Revista*
290 *Mexicana de Ingeniería Química* 15.
- 291 [16] Estrada, B., Alonso, J., 2016. Estudios ecofisiológicos en aguacate cv. Hass en diferentes ambientes como alternativa productiva en Colombia.
292 Ph.D. thesis. Universidad Nacional. Medellín. URL: <http://www.bdigital.unal.edu.co/50844/>.
- 293 [17] Faostat, F., 2020. Statistical databases. Food and Agriculture Organization of the United Nations URL: [http://www.fao.org/faostat/](http://www.fao.org/faostat/es/#data/QC)
294 [es/#data/QC](http://www.fao.org/faostat/es/#data/QC).
- 295 [18] Fuentealba, C., Pedreschi, R., Hernández, I., Jorge, 2016. A STATISTICAL APPROACH FOR ASSESSING THE HETEROGENEITY
296 OF HASS AVOCADOS SUBJECTED TO DIFFERENT POSTHARVEST ABIOTIC STRESSES. *Ciencia e investigación agraria* 43, 2.
297 doi:10.4067/S0718-16202016000300002.
- 298 [19] Garrido, G., Joshi, P., 2018. *OpenCV 3.x with Python By Example - Second Edition: Make the Most of OpenCV and Python to Build*
299 *Applications for Object Recognition and Augmented Reality*. 2nd ed., Packt Publishing.
- 300 [20] Girod, D., 2008. Détermination de la maturité des avocats Hass par imagerie hyperspectrale. Ph.D. thesis. UNIVERSITÉ DU QUÉBEC.
301 URL: http://espace.etsmtl.ca/137/1/GIROD_Denis.pdf.
- 302 [21] Guyon, I., Elisseeff, A., 2003. An Introduction to Variable and Feature Selection. *J. Mach. Learn. Res.* 3, 1157–1182. URL: [http://dl.](http://dl.acm.org/citation.cfm?id=944919.944968)
303 [acm.org/citation.cfm?id=944919.944968](http://dl.acm.org/citation.cfm?id=944919.944968).
- 304 [22] Herrera-González, J.A., Salazar-García, S., Martínez-Flores, H.E., Ruiz-García, J.E., 2017. Preliminary signs of physiological maturity and
305 postharvest performance of méndez avocado fruit | Indicadores preliminares de madurez fisiológica y comportamiento postcosecha del fruto
306 de aguacate méndez. *Revista Fitotecnia Mexicana* 40, 55–63. doi:10.35196/rfm.2017.1.55-63.
- 307 [23] Hunt, E.R., Doraiswamy, P.C., McMurtrey, J.E., Daughtry, C.S.T., Perry, E.M., Akhmedov, B., 2013. A visible band index for remote
308 sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation* 21, 103–112.
309 doi:<https://doi.org/10.1016/j.jag.2012.07.020>.
- 310 [24] ICONTEC, 2003. NTC 5209. Aguacate. Variedades Mejoradas. Especificaciones. Instituto Colombiano de Normas Técnicas y Certificación
311 , 26.
- 312 [25] Kader, A.A., 1999. FRUIT MATURITY, RIPENING, AND QUALITY RELATIONSHIPS. *Acta Horticulturae* , 203–208 URL: https://www.actahort.org/books/485/485_27.htm, doi:10.17660/ActaHortic.1999.485.27.
- 313 [26] Lee Filters, 2020. Technical Filters. 251 Quarter White Diffusion. URL: [http://www.leefilters.com/lighting/colour-details.](http://www.leefilters.com/lighting/colour-details.html#251)
314 [html#251](http://www.leefilters.com/lighting/colour-details.html#251).
- 315 [27] Li, B., Lecourt, J., Bishop, G., 2018. Advances in Non-Destructive Early Assessment of Fruit Ripeness towards Defining Optimal Time of
316 Harvest and Yield Prediction - A Review. *Plants* 7, 3. URL: <http://www.mdpi.com/2223-7747/7/1/3>, doi:10.3390/plants7010003.
- 317 [28] Liu, L., Zhao, L.J., Guo, C.Y., Wang, L., Tang, J., 2018. Texture Classification: State-of-the-art Methods and Prospects. *Zidonghua Xue-*
318 *bao/Acta Automatica Sinica* 44, 584–607. doi:10.16383/j.aas.2018.c160452.
- 319 [29] Magwaza, L.S., Tesfay, S.Z., 2015. A Review of Destructive and Non-destructive Methods for Determining Avocado Fruit Maturity. *Food*
320 *and Bioprocess Technology* 8. doi:10.1007/s11947-015-1568-y.
- 321 [30] MATLAB, 2019. Programming Fundamentals. URL: https://la.mathworks.com/help/pdf_doc/matlab/matlab_prog.pdf.
- 322 [31] Mazhar, M., Joyce, D., Hofman, P., Vu, N., 2018. Factors contributing to increased bruise expression in avocado (*Persea americana* M.) cv.
323 'Hass' fruit. *Postharvest Biology and Technology* 143, 58–67. doi:10.1016/j.postharvbio.2018.04.015.
- 324 [32] Medina-Carrillo, R.E., Salazar-García, S., Bonilla-Cárdenas, J.A., Herrera-González, J.A., Ibarra-Estrada, M.E., Álvarez-Bravo, A., 2017.

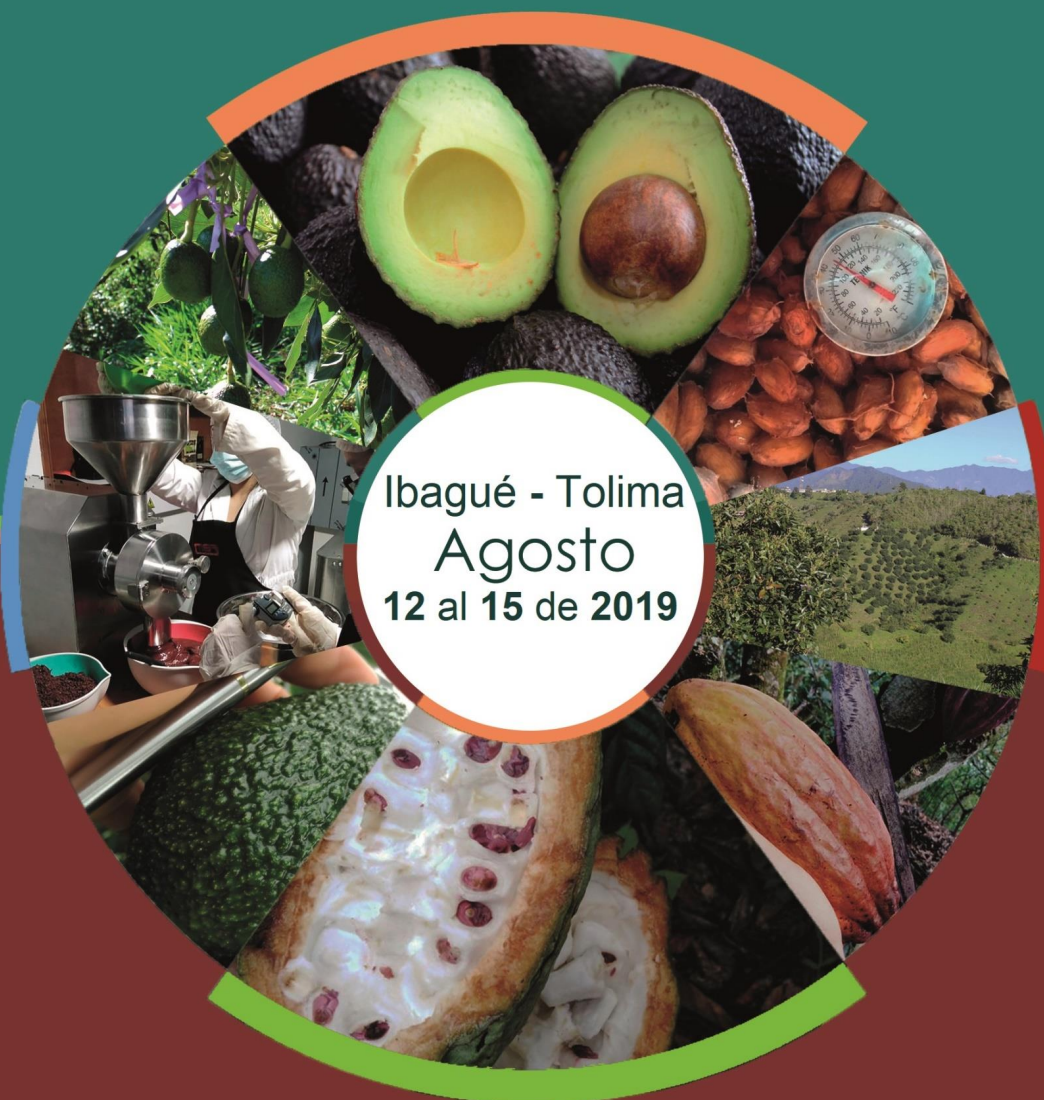
Prediction of physiological maturity of "Hass" avocado by image texture descriptors

- 326 Secondary metabolites and lignin in "hass" avocado fruit skin during fruit development in three producing regions. *HortScience* 52, 852–858.
 327 doi:10.21273/HORTSCI11882-17.
- 328 [33] Ministerio de Agricultura y Desarrollo Rural, 2020. Agronet. Estadísticas Agropecuarias. URL: <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>.
- 329 [34] Nalepa, J., Kawulok, M., 2019. Selecting training sets for support vector machines: a review. *Artificial Intelligence Review* 52, 857–900.
 330 doi:10.1007/s10462-017-9611-1.
- 331 [35] Ncama, K., Magwaza, L.S., Poblete-Echeverría, C.A., Nieuwoudt, H.H., Tesfay, S.Z., Mditshwa, A., 2018. On-tree indexing of 'Hass'
 332 avocado fruit by non-destructive assessment of pulp dry matter and oil content. *Biosystems Engineering* 174, 41–49. doi:10.1016/j.
 333 biosystemseng.2018.06.011.
- 334 [36] Orjuela Vargas, S.A., 2013. Texture analysis for the evaluation of appearance changes in textile surfaces. Ph.D. thesis. Ghent University.
- 335 [37] Pedreschi, R., Muñoz, P., Robledo, P., Becerra, C., Defilippi, B., van Eekelen, H., Mumm, R., Westra, E., De Vos, R., 2014. Metabolomics
 336 analysis of postharvest ripening heterogeneity of 'Hass' avocados. *Postharvest Biology and Technology* 92. doi:10.1016/j.postharvbio.
 337 2014.01.024.
- 338 [38] Rehman, T.U., Mahmud, M.S., Chang, Y.K., Jin, J., Shin, J., 2019. Current and future applications of statistical machine learning algorithms
 339 for agricultural machine vision systems. *Computers and Electronics in Agriculture* 156, 585–605. doi:10.1016/j.compag.2018.12.006.
- 340 [39] Rodríguez, P., Henao, J.C., Correa, G., Aristizabal, A., 2018. Identification of harvest maturity indicators for 'hass' avocado adaptable to field
 341 conditions. *HortTechnology* 28, 815–821. doi:10.21273/HORTTECH04025-18.
- 342 [40] Santana, I., Castelo-Branco, V.N., Guimarães, B.M., Silva, L.D.O., Peixoto, V., Cabral, L.M.C., Freitas, S.P., Torres, A.G., 2019. Hass avocado
 343 (Persea americana Mill.) oil enriched in phenolic compounds and tocopherols by expeller-pressing the unpeeled microwave dried fruit. *Food
 344 Chemistry* 286, 354–361. doi:10.1016/j.foodchem.2019.02.014.
- 345 [41] Schroeder, C.A., 1985. In: *Physiological Gradient in Avocado Fruit*. Avocado Society Yearbook 562, 175–179. URL: <https://pdfs.semanticscholar.org/305a/d15c478bf4e812cc3d782cc606972b0372b5.pdf>.
- 346 [42] Simon, P., Uma, V., 2018. Review of texture descriptors for texture classification, in: *Advances in Intelligent Systems and Computing*, pp.
 347 159–176. doi:10.1007/978-981-10-3223-3{ }15.
- 348 [43] Subedi, P.P., Walsh, K.B., 2020. Assessment of avocado fruit dry matter content using portable near infrared spectroscopy: Method and
 349 instrumentation optimisation. *Postharvest Biology and Technology* 161. doi:10.1016/j.postharvbio.2019.111078.
- 350 [44] Vega Diaz, J.J., Sandoval Aldana, A.P., Reina Zuluaga, D.V., 2020. Prediction of dry matter content of recently harvested 'Hass' avocado
 351 fruits using hyperspectral imaging. *Journal of the Science of Food and Agriculture n/a*. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.10697>, doi:10.1002/jsfa.10697.
- 352 [45] Walsh, K.B., Golic, M., Greensill, C.V., 2004. Sorting of fruit using near infrared spectroscopy: Application to a range of fruit and vegetables
 353 for soluble solids and dry matter content. *Journal of Near Infrared Spectroscopy* 12, 141–148. doi:10.1255/jnirs.419.
- 354 [46] Wedding, B., Wright, C., Grauf, S., White, R.D., Gadek, P.A., Wright, C., Grauf, S., White, R.D., Gadek, P.A., Wright, C., Grauf, S., White,
 355 R.D., Gadek, P.A., 2011. Near infrared spectroscopy as a rapid non-invasive tool for agricultural and industrial process management with
 356 special reference to avocado and sandalwood industries. *Desalination and Water Treatment* 32, 365–372. doi:10.5004/dwt.2011.2723.
- 357 [47] Wedding, B., Wright, C., Grauf, S., White, R.D., Tilse, B., Gadek, P., 2013. Effects of seasonal variability on FT-NIR prediction of dry matter
 358 content for whole Hass avocado fruit. *Postharvest Biology and Technology* 75. doi:10.1016/j.postharvbio.2012.04.016.
- 359 [48] Westad, F., Marini, F., 2015. Validation of chemometric models – A tutorial. *Analytica Chimica Acta* 893, 14–24. doi:<https://doi.org/10.1016/j.aca.2015.06.056>.
- 360 [49] Wiki, 2020. Canon Hack Development Kit (CHDK). URL: <https://chdk.fandom.com/wiki/CHDK>.


Anexo F: Ponencia en congreso internacional




CONGRESO INTERNACIONAL DE CIENCIA
Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE
HASS Y CACAO




Ibagué - Tolima
Agosto
12 al 15 de 2019



GOBERNACIÓN
DEL TOLIMA



Soluciones
que transforman



Universidad
del Tolima
Una nueva historia



CONGRESO INTERNACIONAL DE CIENCIA Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE HASS Y CACAO

CONGRESO INTERNACIONAL DE CIENCIA Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE HASS Y CACAO / María Bianney Bermúdez Cardona, Angélica Piedad Sandoval Aldana Editores Académicos. Ibagué: Gobernación del Tolima, Universidad del Tolima, 2019. 91p

ISSN 2711-0982

Descriptores: Ciencia; Tecnología; Investigación; Aguacate Hass; Cacao.

© **Gobernación del Tolima**

Gobernador
Oscar Barreto Quiroga

© **Universidad del Tolima**

Rector
Omar Alberto Mejía Patiño

Editorial

Universidad del Tolima
Barrio Santa Helena Parte Alta
Teléfono: +57(8)2771212 - 018000181313
Código Postal Nro. 730006299
Ibagué - Tolima. Colombia
cctropico@ut.edu.co
www.ut.edu.co
<http://facultadingeneriaagronomica.ut.edu.co>

Textos, imágenes y fotografías

Comité Organizador CICT.

Diseño, diagramación

Universidad del Tolima

Corrección de estilo

Angélica Piedad Sandoval Aldana

Impresión

Fundación País Humano





CONGRESO INTERNACIONAL DE CIENCIA Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE HASS Y CACAO

Martes 13 de agosto de 2019

- 8:00-9:00 am “Desarrollo y Maduración de Frutas: Una perspectiva molecular”
– Conferencia magistral
PhD. Martín Ernesto Tiznado Hernández
Centro de Investigación en Alimentación y Desarrollo, A.C. (México)
- 9:00-9:45 am “Fisiología reproductiva y comportamiento del Aguacate Hass bajo condiciones tropicales” – Conferencia magistral
PhD. Jairo García Lozano
Universidad del Tolima
(Colombia)
- 9:45-10:15 am “Plataforma informática para manejar la nutrición del aguacate ‘Hass’ y ‘Méndez’ en México”
Ponencia Oral – Arturo Álvarez Bravo Samuel Salazar García; Adriana Mellado Vázquez
- 10:15-10:45 am Refrigerio
- 10:45-11:30 m “Heterogeneidad en la madurez de los frutos de aguacate “Hass” en el árbol y avances para su medición con imágenes hiperespectrales” – Conferencia magistral
cPhD. Jhon Jairo Vega Díaz
Universidad Antonio Nariño (Colombia)
- 11:30-12:00 pm “Estimación de parámetros de calidad poscosecha a partir de imágenes hiperespectrales en aguacate Hass (*Persea americana* Mill)”
Ponencia Oral – Henry Alexander Váquiro Herrera; Angélica Piedad Sandoval Aldana; Luis Daniel Daza Ramirez; Henry Giovanly Cardenas Roa; Angie Katherine Homez Jara; Miguel Angel Montealegre
- 12:00-2:00 pm Almuerzo Libre
- 2:00-2:30 pm “Efecto del incremento en las concentraciones de Caseinato de Sodio sobre las propiedades reológicas interfaciales de espumas obtenidas a partir de emulsiones de aceites de aguacate (*Persea americana*).”
Ponencia Oral – Sergio Andrés Cabrera Navarro; Angélica Sandoval
- 2:30-3:00 pm “La logística de poscosecha en la agrocadena del aguacate en el Tolima: diagnóstico y alternativas de mejora”
Ponencia Oral – Jaime Alberto Villada Gárces; Omar Arley Arenas Quimbayo; Helga Patricia Bermeo Andrade
- 3:00-3:30 pm “Evaluación de parámetros fisicoquímicos de aguacate Hass de la zona de Quindío sometidos a pretratamiento con cera y almacenamiento en frío”
Ponencia Oral – Ángela Del Pilar Sánchez Gonzales; Juan Pablo Benítez Franco; Catherin Julieth Bolaños Cartagena; Laura Juliana Bernal Montoya; Claudia Isabel Ochoa Martínez; Carlos Antonio Vélez Pasos; Angélica Piedad Sandoval Aldana
- 3:30-4:00 pm Refrigerio
- 4:00-4:30 pm “Estudios preliminares de los efectos del ácido cítrico y exposición a microondas sobre la actividad enzimática, vida de anaquel y viabilidad económica del puré de Aguacate Hass congelado”
Ponencia Oral – Sebastian Ospina Corral; Catalina Álvarez Campusano; Carlos Eduardo Orrega Alzate
- 4:30-5:30 pm Visitas y Exposición de Posters
- 5:30-6:00 pm Entrega de certificados y Clausura
Lugar: Universidad del Tolima, Terrazas del Bloque 33

15



Universidad
del Tolima
Una nueva historia

Facultad de Ingeniería
Agronómica





CONGRESO INTERNACIONAL DE CIENCIA Y TECNOLOGÍA EN EL TRÓPICO: AGUACATE HASS Y CACAO

Heterogeneidad en la madurez de los frutos de aguacate en el árbol y avances para su medición con imágenes hiper-espectrales

cPhD. Jhon Jairo Vega Díaz
Universidad Antonio Nariño

Para los agricultores se dificulta la determinación del momento óptimo de cosecha del fruto de aguacate variedad "Hass" con fines de exportación; una de las causas principales es la heterogeneidad de su madurez en el árbol, la cual es medida con métodos destructivos en términos de porcentaje de materia seca (M.S.). Para evidenciar el nivel de heterogeneidad se realizó una medición del porcentaje de materia seca de todos los frutos de un árbol en temporada de cosecha, en el municipio de Fresno-Tolima, concluyendo que en el árbol hay frutos en un rango del 22% M.S.. Por tanto, para mejorar la clasificación de la madurez de la fruta con fines de exportación, se desarrolló un modelo predictivo para determinar el porcentaje de materia seca del fruto recién cosechado, con el uso de imágenes hiper-espectrales, tomadas con una cámara Pika XC2, del rango visible en infrarrojo cercano, en condiciones controladas. El modelo de predicción usa la regresión lineal múltiple, donde la variable dependiente es el porcentaje de materia seca y las variables independientes son los valores espectrales por longitud de onda, el porcentaje de materia seca se determinó en laboratorio mediante desecación en horno y el espectro del fruto corresponde a el valor promedio de la reflectancia transformado a la segunda derivada de los valores de absorbancia; Los algoritmos usados fueron: regresión lineal múltiple (MLR), regresión con componentes principales (PCR), regresión con mínimos cuadrados parciales (PLS), regresión lineal con máquina de soporte vectorial (SVRL) y regresión con redes neuronales (NN); Para reducir el número de bandas del espectro se calculó los valores beta de un modelo lineal mediante máquina de soporte vectorial y se eliminó de forma recurrente de la banda con menor valor Beta seleccionando las bandas con mayor valor de R2 en validación cruzada. Los algoritmos fueron entrenados con 584 fotos de 304 frutos, el espectro correspondió a 95 bandas. El valor de R2 para cada modelo fue: en validación cruzada MLR=0.89, PCR=0.70, PLS=0.8, SVRL=0.89 y test NN=0.94; El valor de RMSE para cada modelo fue: en validación cruzada MLR=2.75, PCR=4.53, PLS=3.67, SVRL=2.74 y test NN=8.63. Como conclusiones los frutos de aguacate presentan heterogeneidad de maduración en el árbol y el uso de imágenes hiper espectrales para predecir el contenido de materia seca de los frutos de aguacate, recién cosechados, es un método viable y como próximos pasos a seguir se va a refinar el modelo de predicción con un mayor número de datos y se va a validar en otras regiones con condiciones climáticas diferentes.



Anexo G: Lienso CANVAS del modelo de negocio

<p><i>Key Partners</i></p> <ul style="list-style-type: none"> • Vendedores de servicio web • Vendedores de dispositivos • Asociaciones de agricultores 	<p><i>Key Activities</i></p> <ul style="list-style-type: none"> • Mercadeo • Mantenimiento de la plataforma • Asesorías • Parametrización del modelo 	<p><i>Value Proposition</i></p> <p>Cosechar la fruta de aguacate con la madurez óptima para exportación</p> <ul style="list-style-type: none"> • Servicio de cosecha • Dispositivo <ul style="list-style-type: none"> ▪ Portal web de parametrización • Servicios personalizados de integración de datos. 	<p><i>Customer Relationships</i></p> <ul style="list-style-type: none"> • Servicio de cosecha • Venta del dispositivo • Parametrización del modelo • Servicios personalizados 	<p><i>Customer Segments</i></p> <p>Agricultores de aguacate para exportación</p> <ul style="list-style-type: none"> • Pequeños agricultores (1) • Asociaciones (2) • Grandes agricultores (3)
<p><i>Cost Structure</i></p> <ul style="list-style-type: none"> • Partes del dispositivo • Parametrización del modelo • Procesamiento web • Salarios / comisiones • Administración 		<p><i>Revenue Streams</i></p> <ul style="list-style-type: none"> • Prestar el servicio de cosecha (1) • Vender el dispositivo (1-2-3) • Servicio bajo demanda (2-3) 		