



UNIVERSIDAD  
DE PIURA

REPOSITORIO INSTITUCIONAL  
PIRHUA

# APLICACIÓN DE PROCESAMIENTO DE IMÁGENES PARA CLASIFICACIÓN DE GRANOS DE CACAO SEGÚN SU COLOR INTERNO

Gabriela Viera-Maza

Piura, marzo de 2018

FACULTAD DE INGENIERÍA

Máster en Ingeniería Mecánico-Eléctrica con Mención en Automática y  
Optimización

Viera, G. (2018). *Aplicación de procesamiento de imágenes para clasificación de granos de cacao según su color interno* (Tesis de Máster en Ingeniería Mecánico-Eléctrica con Mención en Automática y Optimización). Universidad de Piura. Facultad de Ingeniería. Piura, Perú.



Esta obra está bajo una licencia

[Creative Commons Atribución-NoComercial-SinDerivar 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)

[Repositorio institucional PIRHUA – Universidad de Piura](https://repositorio.institucional.pirhua.edu.pe/)

UNIVERSIDAD DE PIURA  
FACULTAD DE INGENIERÍA



“Aplicación de procesamiento de imágenes para clasificación de granos de cacao según su color interno”

Tesis para optar el Título de  
Máster en Ingeniería Mecánico-Eléctrica con mención en Automática y Optimización

Gabriela Isamar Viera Maza

Asesor: Mgtr. Juan Carlos Soto Bohórquez

Piura, Marzo 2018





A Dios por estar siempre conmigo  
A mis queridos padres  
Olga y Luis  
y a mis hermanos  
Luis y Juan Carlos  
por su incansable apoyo.







## Prólogo

La agricultura es una actividad muy importante e integral de la economía nacional. La producción, conservación, comercio y consumo de productos agrícolas son aspectos importantes para la estabilidad de la economía agrícola de un país. La Región Piura, con sus diferentes climas y suelos, es una tierra adecuada para la siembra de diversos productos agrícolas como son: ají piquillo, cacao, café, banano, frijol castilla, frijol de palo, limón, lúcuma, mangos, papaya, paprika, uva de mesa, etc.

Actualmente, la calidad y la seguridad de productos son factores fundamentales para el crecimiento de la industria agrícola. En esta industria, la evaluación de la calidad de los productos agrícolas sigue realizándose mediante la inspección visual por personal experimentado, sin embargo, este tipo de inspección es subjetiva, tediosa, inconsistente, y costosa.

Otras técnicas de evaluación de calidad son los métodos químicos y cromatográficos como la espectrometría de masas, cromatografía de gases, y cromatografía líquida de alto rendimiento (HPLC); cuya desventaja es ser métodos destructivos, lentos, tediosos, dañinos para el medio ambiente, y costosos. Por ello, se han desarrollado métodos de análisis no destructivos, rápidos, eficientes, y de costo asequible. Algunos ejemplos serían: técnicas de ultrasonido, narices electrónicas, espectroscopia, visión artificial o por computador, y visión hiperspectral. En los últimos años, existen más investigaciones que utilizan imágenes hiperspectrales para evaluación de calidad de productos agrícolas.

El enfoque principal de la tesis es el cacao piurano. Debido a su reconocimiento en el mercado mundial, se requieren adecuadas técnicas de cultivo y postcosecha para obtener la mejor calidad de cacao. El principal problema de la producción de cacao es que los países productores utilizan diferentes prácticas de cultivo y postcosecha pues no están claramente definidas las condiciones para una producción de granos de cacao de alta calidad. Otro problema es que algunos agricultores mezclan intencionalmente granos de cacao sin fermentar con los fermentados para satisfacer la demanda de los compradores.

La fermentación es esencial para el desarrollo de precursores del sabor y color, y reducción de amargor en los granos de cacao. Tradicionalmente, el grado de fermentación se evalúa mediante la prueba de corte en la que se cortan los granos transversalmente y se registra el color de los cotiledones. Los granos poco fermentados son morados o pizarrosos y tiene un sabor astringente debido a la presencia de antocianinas, y los granos fermentados son de color marrón. Esto sugiere que la concentración de antocianinas es un índice útil del grado de fermentación.

Las asociaciones de productores de la región de Piura cuentan con sistemas mecánicos de clasificación pero no siempre presenta resultados satisfactorios. En la asociación de productores ASPROBO, se utiliza una máquina tamizadora para la clasificación de granos según el tamaño y se realiza una prueba de corte; si los granos defectuosos no superan el 20% del total de granos, el total es considerado de “buena fermentación”. El técnico encargado de la clasificación se basa en el color interno del grano.

Es importante expresar mi agradecimiento a las personas que me ayudaron en el desarrollo de la presente tesis, a los productores de cacao Buenos Aires (Morropón, Piura), en especial a la asociación ASPROBO, quienes nos mostraron el proceso de clasificación de granos de cacao y facilitaron las muestras de granos de cacao que permitieron la elaboración de la base de datos utilizada en esta tesis.

También es de agradecer al Laboratorio de Sistemas Automáticos de Control de la Facultad de Ingeniería Mecánico Eléctrica de la Universidad de Piura, especialmente al Dr. William Ipanaqué Alama, y al Mgtr. Juan Carlos Soto Bohórquez, asesor de la presente tesis, por confiar en mi persona y brindarme su apoyo.

Y agradezco la gran ayuda recibida por parte de mis padres y hermanos, quienes me han apoyado con su ánimo y paciencia.

## **Resumen**

Este trabajo establece los conceptos básicos para el desarrollo de la visión hiperespectral aplicada a la agroindustria nacional. El principal objetivo es el desarrollo de un sistema de visión hiperespectral para la clasificación de granos de cacao intactos según su color interno en la fase de cosecha.

La tesis está dividida en cinco capítulos de desarrollo teórico y experimental, un capítulo de conclusiones y recomendaciones, referencias, y finalmente los anexos.

Los aspectos básicos de esta investigación se resumen en el primer capítulo, como el estado del arte y la problemática de la producción de cacao. En el segundo capítulo, se presenta los fundamentos y configuración de un sistema hiperespectral, conceptos básicos para el análisis de imágenes, y ventajas, desventajas y aplicaciones de la visión hiperespectral.

En el tercer capítulo, se presenta una descripción del sistema utilizado, del software y la interfaz gráfica. La aplicación del sistema se describe en el cuarto capítulo, detallando el material de estudio y la metodología utilizada.

En el quinto capítulo, se presentan los resultados del sistema para la clasificación de grano de cacao, obteniéndose un porcentaje promedio de acierto de 85.7%. Y finalmente en el sexto capítulo se presentan las conclusiones de la tesis.



# Índice

Prólogo .....	i
Resumen .....	iii
Índice... ..	v
Introducción.....	1
1 Marco Teórico .....	3
1.1 Estado del Arte.....	3
1.2 Producción de cacao .....	12
1.2.1 Descripción de la planta .....	13
1.2.2 Beneficio o tratamiento postcosecha .....	17
2 Visión Hiperespectral .....	25
2.1 Fundamentos de la imagen hiperespectral .....	25
2.1.1 Fundamentos de la visión artificial.....	26
2.1.2 Fundamentos de la espectroscopia .....	30
2.1.3 Espectro electromagnético.....	32
2.1.4 Conceptos básicos .....	33
2.2 Configuración de sistema de visión hiperespectral.....	36
2.2.1 Modos de adquisición de imágenes hiperespectrales .....	36
2.2.2 Principales componentes del sistema hiperespectral .....	39
2.3 Análisis de imagen hiperespectral .....	42
2.3.1 Pretratamiento espectral y calibración.....	44
2.3.2 Clasificación .....	45
2.4 Ventajas y desventajas .....	50
2.4.1 Ventajas de la imagen hiperespectral .....	50
2.4.2 Desventajas y limitaciones de la imagen hiperespectral .....	50
2.5 Aplicaciones.....	51
3 Materiales y métodos.....	53
3.1 Sistema de imágenes hiperespectrales .....	53
3.1.1 Calibración del sistema Resonon.....	56

3.1.2	Software de adquisición de datos .....	61
3.2	Interfaz gráfica .....	63
4	Aplicación de sistema de imágenes hiperespectrales .....	67
4.1	Material de estudio e identificación .....	67
4.1.1	Antocianina .....	67
4.1.2	Índices espectrales de vegetación .....	70
4.1.3	Modelo de clasificación SVM .....	75
4.2	Metodología .....	76
4.2.1	Entrenamiento y validación .....	76
4.2.2	Aplicación .....	79
5	Resultados y discusión .....	81
5.1	Entrenamiento y validación .....	82
5.2	Aplicación .....	83
6	Conclusiones .....	87
	Referencias .....	89
	ANEXOS .....	97

## **Introducción**

La visión hiperespectral es una tecnología emergente que comenzó con aplicaciones en la astronomía y teledetección. Debido al avance tecnológico, esta técnica se ha aplicado en varios campos como ciencias forenses, bioquímica, medicina, farmacéutica, minería, e industria alimenticia. En especial, existen varias investigaciones sobre la evaluación de la calidad de productos agrícolas, por ejemplo, la determinación del contenido de sólidos solubles y firmeza, evaluación de acidez, detección de daños o infecciones, determinación del contenido de azúcar, evaluación del estado de madurez, y determinación del contenido de pigmentos.

Por la combinación de técnicas de procesamiento de imágenes y espectroscopia, la imagen hiperespectral otorga información espacial y espectral de los diferentes componentes de una muestra analizada. El espectro correspondiente a cada píxel en una imagen hiperespectral puede utilizarse como huella digital para definir la composición química del píxel.

La imagen hiperespectral proporciona abundante información espectral a partir de la cual se extraen características fundamentales para el análisis de la muestra. Estas imágenes pueden analizarse, de forma rápida y no invasiva, características físicas y químicas de un producto para la evaluación de su calidad. Generalmente, se selecciona un conjunto de longitudes de onda para desarrollar un sistema multiespectral y así evitar la información redundante del sistema hiperespectral. Sin embargo, se debe considerar la posible pérdida de información importante de los datos hiperespectrales originales.

El objetivo principal de este trabajo es desarrollar un sistema de clasificación de grano de cacao orgánico según su color interno en fase de cosecha utilizando imágenes hiperespectrales. Para lograr este objetivo se debe desarrollar un software para el procesamiento de las imágenes hiperespectrales de los granos de cacao.





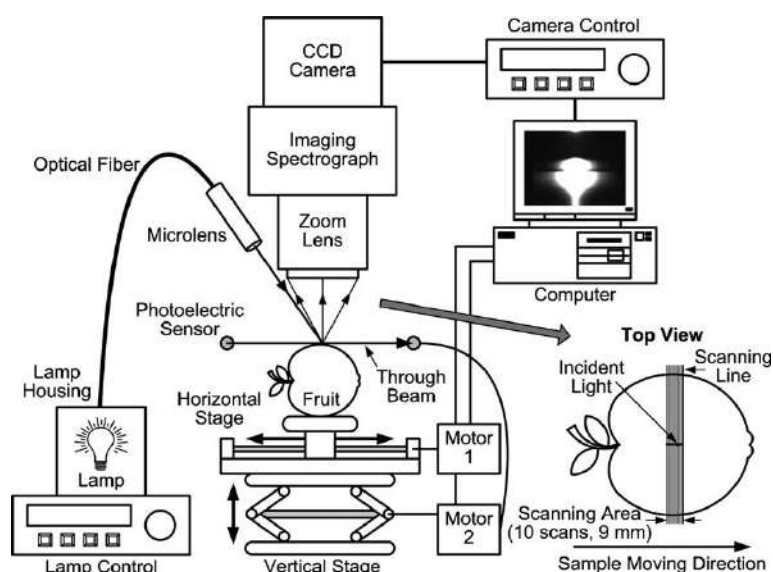
## Capítulo 1

### Marco Teórico

#### 1.1 Estado del Arte

Este trabajo se centra en la técnica de visión hiperespectral aplicada para determinar el contenido de pigmentos en granos intactos de cacao en la etapa de cosecha, por ello se ha elaborado una revisión de artículos que analizan información espectral de productos agrícolas para distintas aplicaciones.

Utilizando una técnica de reflectancia difusa, en (Qin & Lu, 2008), se determinó algunas propiedades ópticas de frutas y vegetales en la región visible y de ondas cortas del infrarrojo cercano (500-1000 nm). En la Figura 1, se muestra el sistema hiperespectral utilizado en modo de escaneo lineal para obtener imágenes de reflectancia difusa de manzanas (tres variedades), melocotón, pera, kiwi, ciruela, pepino, calabacín y tomate (en tres etapas de madurez).



**Figura 1.** Sistema hiperespectral para la adquisición de imágenes de dispersión espacialmente resueltas de una muestra de fruta.

Fuente: Qin & Lu, 2008

El contenido de azúcares, antocianinas y el pH en uvas, se determinó en (Fernandes et al., 2015). El espectro de cada muestra, compuesta de seis bayas de uva enteras, se obtuvo utilizando imágenes hiperespectrales en el modo de reflectancia de 380 a 1028 nm. El conjunto de pruebas con 30 muestras reveló valores  $r^2$  (coeficiente de determinación) de 0.73, 0.92 y 0.95, y RMSE (error cuadrático medio) de 0.18, 0.95°Brix y 14 mg/l para pH, azúcares y contenido de antocianinas, respectivamente.

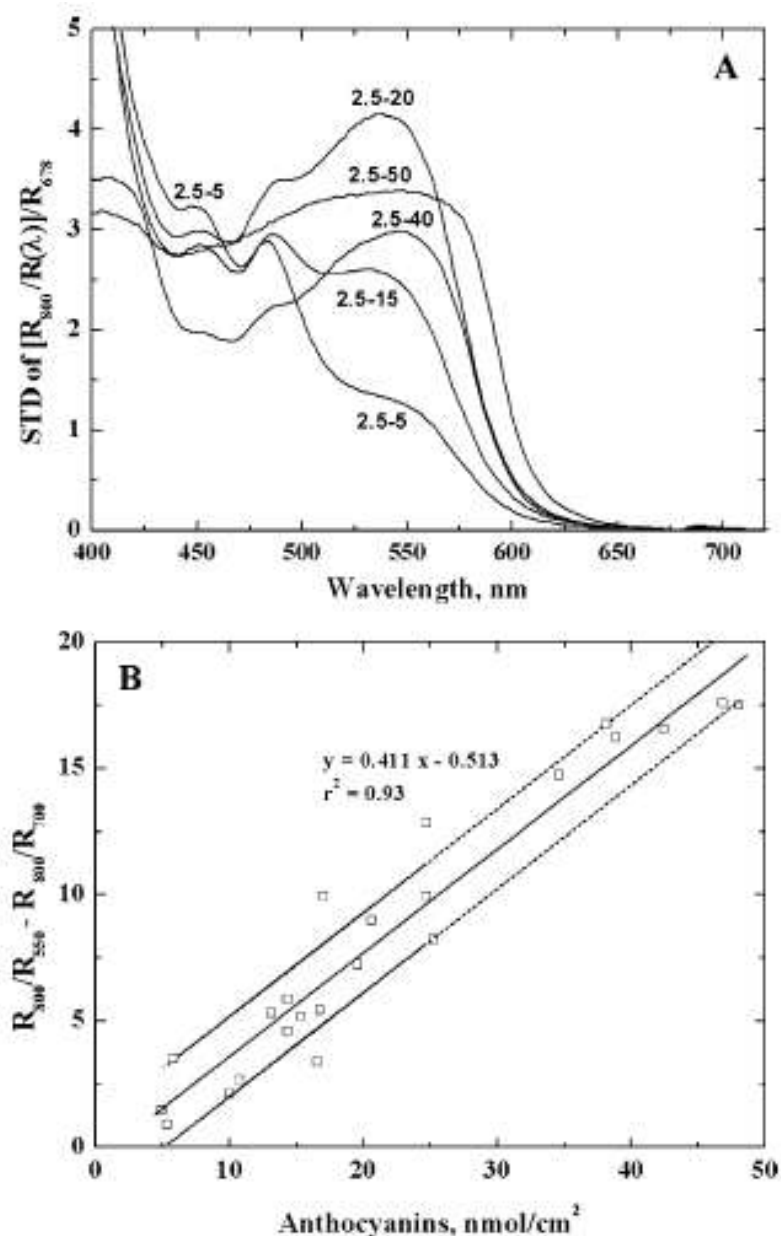
Debido a su gran cantidad de información, se desarrolló un análisis espectral basado en un número limitado de longitudes de onda especiales o índices de vegetación para determinar características de productos agrícolas. Los índices espectrales pueden consistir en una única longitud de onda, diferencias o relaciones entre longitudes de onda. A continuación se presentan la aplicación de índices espectrales para la predicción de propiedades de frutos, como el grado de madurez, contenido de pigmentos, contenido de flavonol, entre otros.

En (Merzlyak et al., 1999) se presentó una técnica no destructiva basada en espectros de reflectancia visible/infrarrojo cercano (Vis/NIR) para estimar los rasgos característicos de la senescencia foliar natural y la maduración de frutos. Se encontró que el Índice de Reflectancia Senescente de la Planta en la forma  $PSRI = (R_{678} - R_{500})/R_{750}$ , era sensible a la relación carotenoides/clorofila.

Posteriormente, los espectros de reflectancia de cinco distintos cultivos de manzana madura se estudiaron en (Merzlyak et al., 2003a). Se encontró que la reflectancia en 520-530 nm dependía principalmente de los carotenoides y se sugirió el índice  $R_{800}(1/R_{520} - 1/R_{700})$  para la estimación del contenido de carotenoides en el intervalo de 0.6-4.5 nmol/cm<sup>2</sup>. El índice para la evaluación de una relación carotenoide/clorofila se propuso en la forma  $(R_{480} - R_{678})/R_{800}$  y se desarrolló el índice  $R_{800}(1/R_{550} - 1/R_{700})$  para estimar el contenido de antocianina en la cáscara comprendida entre 2.5 y 50 nmol/cm<sup>2</sup>. En la Figura 2, se presentan los espectros de desviación estándar (STD) de la función  $[R_{800}/R(\lambda)]/R_{678}$  para frutos con un contenido de antocianinas en nmol/cm<sup>2</sup> (A) y la relación de la relación de reflectancia  $R_{800}(1/R_{550} - 1/R_{700})$  frente al contenido de antocianina (B).


Finalmente en (Merzlyak et al., 2005) se investigó las propiedades espectrales de flavonoles de tres variedades de manzana libre de antocianinas. El modelo para la evaluación del contenido de flavonol fue sugerido en la forma de índice de reflectancia de flavonol  $FRI = (R_{410}^{-1} - R_{460}^{-1})R_{800}$ . El modelo se relacionó linealmente con el contenido de flavonol entre 8 y 220 nmol/cm<sup>2</sup> con el coeficiente ( $r^2 = 0.92$ ) y el error cuadrático medio de la estimación de flavonol de 20 nmol/cm<sup>2</sup>.

En el análisis de cultivos de manzanas también se puede mencionar la investigación realizada por (Chivkunova et al., 2001), donde se estudiaron los espectros de reflectancia de manzanas en los rangos visible e infrarrojo cercano durante su almacenamiento. Durante la maduración del fruto sin escaldado superficial, se encontró una alta correlación entre las reflectancias a 550 y 700 nm. Las firmas espectrales anteriormente mencionadas se utilizaron para definir el Índice de reflectancia de marrón  $BRI = (1/R_{550} - 1/R_{700})/R_{750}$  para la detección no destructiva de escaldado superficial.



**Figura 2.** Los espectros de desviación estándar (STD) de la función  $[R_{800}/R(\lambda)]/R_{678}$  para frutos con un contenido de antocianinas nmol/cm<sup>2</sup> (A) y la relación de reflectancia  $R_{800}(1/R_{550} - 1/R_{700})$  frente al contenido de antocianina (B).  
Fuente: Merzlyak et al., 2003a.

Un análisis espectral-óptico del contenido de clorofila en manzanas con un espectrómetro portátil miniaturizado se llevó a cabo en (Zude, 2003), se realizaron grabaciones espectrales de transmitancia en el rango de longitud de onda visible que se muestran en la Figura 3. El contenido de clorofila-a de las manzanas se midió químicamente y se predijo mediante índices específicos como Índice de Vegetación de Diferencia Normalizada (NDVI),  $Tr_{698}/Tr_{760}$ , borde-rojo,  $TrII$  en  $Tr'(\lambda)$ ,  $TrII$  e Índice de Tensión de la Vegetación de borde Rojo (RVSI) con coeficientes  $r^2 = 0.84, 0.81, 0.75, 0.81, 0.15$  y  $0.67$ , respectivamente.



**Figura 3.** Vista esquemática de las mediciones espectrales realizadas sobre las manzanas.  
Fuente: Zude, 2003.


En (Herold et al., 2005), las mediciones de maduración de los frutos en el árbol se llevaron a cabo utilizando un módulo espectrofotométrico mostrado en la Figura 4, se detectó la transmitancia de luz parcial a través de la fruta en un intervalo de longitud de onda de 500 a 1000 nm. A partir de los datos espectrales, se obtuvieron diferentes índices para caracterizar el cambio de pigmento del fruto y el progreso de la madurez de frutos. El borde rojo, así como un índice de clorofila normalizado (CHL)  $[(R_{760} - R_{695}) / (R_{760} + R_{695})]$  exhibió una disminución moderada, mientras que un índice de antocianina normalizado (ANT)  $[(R_{760} - R_{570}) / (R_{760} + R_{570})]$  aumentó sigmoidalmente. Posteriormente en (Geyer et al., 2007), la etapa de madurez del fruto fue descrita por dos índices espectrales no destructivos que describen la disminución de la clorofila y el aumento de las antocianinas durante el progreso de la madurez del fruto.



**Figura 4.** Utilización de la sonda de fibra de vidrio del espectrofotómetro portátil; la caja en el antebrazo contiene el módulo del espectrómetro miniaturizado.

Fuente: Herold et al., 2005.

El contenido de clorofila en la piel de manzanas se determinó en (Rutkowski et al., 2008), también se evaluó los parámetros de calidad y madurez del fruto utilizando espectrometría de reflectancia óptica. Los parámetros de calidad se midieron usando el Medidor de Contenido de Clorofila CCM-200 y el Analizador de Pigmentos CP PA1101. Los resultados de la medición usando CCM-200 se expresaron como Índice de Clorofila. Se utilizó CP PA1101 para calcular el índice  $NDVI = (I_{780} - I_{660}) / (I_{780} + I_{660})$  y el índice de antocianina normalizado  $NAI = (I_{780} - I_{570}) / (I_{780} + I_{570})$ . En la Figura 5, se presentan los cambios en NDVI e NAI durante la maduración de la fruta “Golden Delicious”.



**Figura 5.** Los cambios en NDVI e NAI durante la maduración de la fruta “Golden Delicious”.

Fuente: Rutkowski et al., 2008.


Para desarrollar un índice de madurez de frutos, en (Ziosi et al., 2008), se relacionó la diferencia de absorbancia de dos longitudes de onda cerca del pico de absorción de clorofila-a (670 y 720 nm), denominada Índice de Diferencia de Absorbancia ( $I_{AD} = A_{670} - A_{720}$ ), con la producción de etileno durante la maduración de melocotones y nectarinas. Se utilizó la relación  $I_{AD}$ /producción de etileno para clasificar los frutos en la cosecha de acuerdo a su etapa de maduración (clase 0: pre-climaterio, clase 1: inicio del climaterio, clase 2: climaterio).

El índice  $I_{AD}$  también se utilizó en (Infante et al., 2011), donde el proceso de maduración fue monitoreado en el árbol y durante la postcosecha de manera no destructiva, a través de la absorbancia de la clorofila ( $I_{AD}$ ), la resistencia a la compresión de la fruta intacta y los parámetros tradicionales asociados con la maduración de la ciruela japonesa. El  $I_{AD}$  frente al tiempo mostró los mayores coeficientes de determinación en comparación con la firmeza de la pulpa, el contenido de sólidos solubles, el tono ( $H^{\circ}$ ) y el croma ( $C^*$ ) de la piel.

En (Lleó et al., 2011) se utilizan imágenes hiperespectrales para evaluar la maduración de melocotones de piel roja y piel blanda. Los índices ópticos considerados ( $I_{AD}$ ,  $Ind_1 = [(R_{700} + R_{640}) - 2R_{680}]$ ,  $Ind_2 = [R_{680}/(R_{700} + R_{640})]$ ,  $Ind_3 = R_{680}/R_{700}$ ), se basan en la combinación de longitudes de onda cercanas al pico de absorción de clorofila a 680 nm para discriminar entre las etapas de maduración. El comportamiento de los cuatro índices en relación con la maduración del melocotón fue:  $Ind_2 > Ind_1 > I_{AD} > Ind_3$ . El índice  $Ind_2$  mostró el mayor poder de discriminación entre las etapas de maduración, permitió la diferenciación de las regiones de maduración dentro de los frutos, y mostró la evolución de esas regiones durante la maduración.

Con el objetivo de estimar la firmeza de manera no destructiva en manzanas “Braeburn” y “Cripps Pink”, en (Zanella et al., 2012) se compararon tres índices de madurez óptica basados en el contenido de clorofila: el coeficiente de absorción medido a 670 nm ( $\mu_a670$ ), el índice  $I_{AD}$  y el índice NDVI. En “Braeburn”, la firmeza se correlacionó bien con el  $\mu_a670$  y, con menor relación, con los índices  $I_{AD}$  y NDVI. Por el contrario, en “Cripps Pink” no se encontraron correlaciones entre la firmeza y los índices ópticos.


En (Yang et al., 2012), se desarrolló una clasificación de frutos y hojas de arándanos a base de firmas espectrales en el rango de 200-2500 nm. Las muestras se dividieron en hojas, fruta madura, fruta casi madura, fruta casi joven y fruta joven. Los índices normalizados se utilizaron como variables candidatas para la clasificación. Un modelo de regresión logística multinomial (MNR) con seis longitudes de onda fue el mejor modelo, con una precisión de predicción de 100% para hojas y frutos maduros, 97.8% para frutos jóvenes, 97.9% para fruta casi joven y 94.6% para frutos casi maduros. Las absorbancias de distintas etapas de crecimiento de la fruta y hojas de arándanos se presentan en la Figura 6.



**Figura 6.** Absorbancia de diferentes etapas de crecimiento de la fruta y hojas de arándanos. Todos los espectros son promedios de siete variedades.

Fuente: Yang et al., 2012.

Finalmente en (Ruiz et al., 2016) se presentó un estudio del análisis hiperespectral en la fermentación de granos de cacao violeta, basado en el cálculo de índices espectrales. Se encontró una correlación entre algunos parámetros bioquímicos (pH, temperatura y porcentaje de humedad) y los índices hiperespectrales ARI2 (Índice de Reflectancia de Antocianina 2), RBE (Relación de Bandas Espectrales) y RBEAE (Relación de Bandas Espectrales de Absorción Externa). En la Figura 7, se muestra la evolución del índice ARI2 del cotiledón en el proceso de fermentación del cacao.



**Figura 7.** Evolución de ARI2 del cotiledón en el proceso de fermentación del cacao.  
Fuente: Ruiz et al., 2016.


Los métodos utilizados para la evaluación de la calidad de granos de cacao, tales como la cromatografía de gases, HPLC, índice de fermentación, prueba sensorial, y la prueba de corte, generalmente son tediosos, lentos, caros, o destructivos y requieren una preparación cuidadosa de la muestra. Por ello, nuevas técnicas se han utilizado para determinar los diversos componentes de los granos de cacao, ofreciendo una alternativa rápida en comparación con los métodos analíticos tradicionales.

En (Aculey et al., 2010), una combinación de métodos incluyendo la prueba de corte, colorimetría, espectroscopia de fluorescencia, espectroscopia NIR, y cromatografía de gases-espectrometría de masas (GC-MS), se utilizó para examinar granos de cacao de diferentes regiones de cultivo en Ghana y con diferentes duraciones de fermentación.

En (Afoakwa et al., 2012) se realizaron estudios para evaluar los efectos del almacenamiento de vainas y el tiempo de fermentación sobre la calidad fermentativa y el aspecto de los granos de cacao de Ghana. La calidad fermentativa (corte de prueba e índice de fermentación FI) y el color (L, a, b) de los granos de cacao se estudiaron utilizando métodos estándar. El índice de fermentación de la muestra se obtuvo calculando la relación de absorbancia a 460 nm y a 530 nm.



Varios granos de cacao de Ghana fueron clasificados según su origen geográfico en (Teye et al., 2013) aplicando la técnica de espectroscopia NIR y cuatro métodos de clasificación multivariable: Análisis discriminante lineal (LDA), K-vecinos más cercanos (KNN), Red neuronal artificial de propagación posterior (BP-ANN) y Máquina de Vector de Soporte (SVM). Los resultados revelaron que el modelo SVM fue el mejor con una tasa de discriminación del 100% tanto en el entrenamiento como en el pronóstico. Los espectros medios del grano de cacao de siete regiones se presentan en la Figura 8.







**Figura 8.** Espectros medios del grano de cacao de siete regiones.  
Fuente: Teye et al., 2013.

La espectroscopia de infrarrojo cercano con transformada de Fourier (FT-NIR) combinada con la SVM y parcial mínimo cuadrado del intervalo sinérgico (Si-PLS) se utilizó en (Teye et al., 2014), para la identificación de granos de cacao fermentados y no fermentados. Y en (Teye et al., 2015) se utilizó FT-NIR y técnicas quimiométricas para estimar las categorías de calidad de los granos de cacao: pH e índice de fermentación (FI). El modelo de identificación óptima BP-ANN fue de 99.73%. El modelo de selección de variables eficientes derivadas de la regresión de la red neuronal artificial de la propagación trasera del intervalo de sinergia (Si-BPANNR) mejoró la estimación de FI y pH.

El objetivo de (Alas & Morales, 2015) fue estandarizar el proceso de fermentación de la mezcla de semillas de tres accesiones de cacao del cultivar San José del Real. El índice de fermentación, se realizó tomando muestras de semillas de cacao fermentadas y secas (ver Tabla 1), a partir del día 0 al día 5 de fermentación, estas se trituraron y extrajeron sus componentes con una mezcla de metanol-ácido clorhídrico, en proporciones de 97:3, luego se leyeron las absorbancias a 530nm y 460nm, en un espectrofotómetro UV/Vis, posteriormente se realizó la relación de las absorbancias, para obtener el índice de fermentación, en los cuatro ensayos, se obtuvieron valores mayores de 1, en el día 5 del proceso, con ello se concluye, que 5 son los días que se debe fermentar, las semillas de cacao, para obtener buenas características en el grano, ya que estudios científicos, realizados en otros países determinan, que valores de 1 o mayores de 1 son los aceptados.




**Tabla 1.** Mezclas para toma de índice de fermentación.

Días de Fermentación	Antes de Refrigerar	Después de Refrigerar
Mezclas Día 0		
Mezclas Día 1		

Fuente: Alas &amp; Morales, 2015.

Finalmente en (Sunoj et al., 2016) se predijo parámetros de calidad del grano de cacao, como el índice de fermentación, el pH y el contenido total de polifenoles utilizando la espectroscopia NIR con transformada de Fourier (FT). Las muestras se escanearon en la región NIR en el rango de  $12500 - 3600 \text{ cm}^{-1}$  para el análisis espectral (ver Figura 9). Los resultados obtenidos del análisis de calidad convencional se correlacionaron con los espectros, se utilizó la técnica de regresión de mínimos cuadrados parciales para desarrollar los modelos de calibración, resultando en la predicción del índice de fermentación y polifenoles totales ( $r^2 \geq 0.80$ ), y en el pH ( $r^2 < 0.80$ ).

**Figura 9.** Espectros FT-NIR obtenidos para granos de cacao en toda la región.

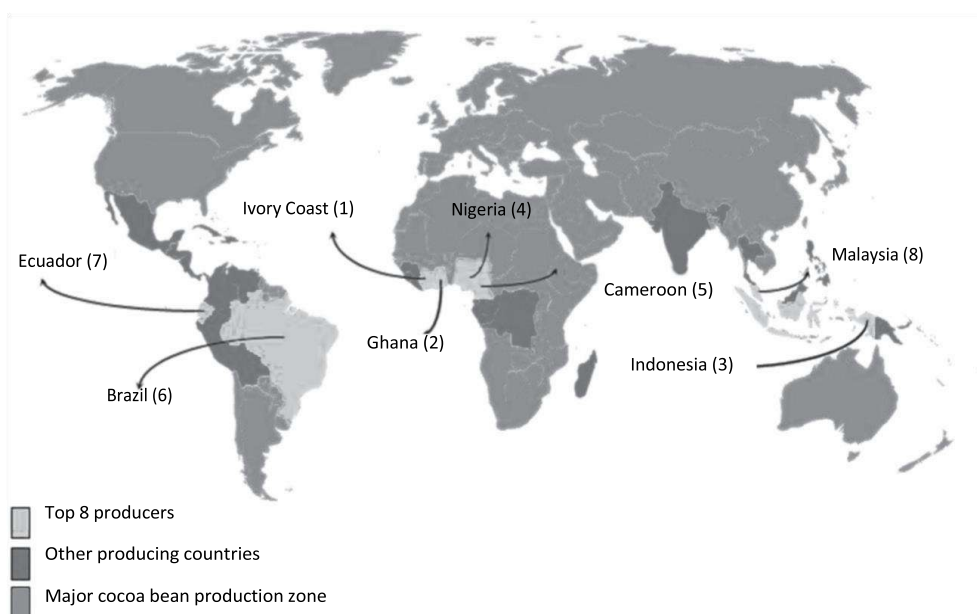
Fuente: Sunoj et al., 2016.

Las imágenes hiperespectrales también se han utilizado para analizar la composición de granos de cacao, como en (Zulfahrizal et al., 2016) que analizó el contenido de grasa de los granos de cacao intactos. Se obtuvieron datos espectrales, en forma de reflectancia difusa, en el rango de 1000 a 2500 nm. El contenido de grasa se midió con el método de Soxhlet. El modelo de calibración utilizado fue la regresión de máquina de vector de soporte (SVMR). El coeficiente de correlación entre los datos reales y predichos ( $r$ ) fue de 0.84 y el índice de desviación predictiva residual (RPD) de 1.65, se concluye que el modelo es adecuado.

## 1.2 Producción de cacao

En el 2010, “World Cocoa Foundation” estimó que el número de productores de cacao a nivel mundial era aproximadamente de 5 a 6 millones y el número de personas que dependían del cacao como medio de vida era de 40 a 50 millones. Además se estimó que el valor del cultivo anual de cacao en el mercado global era de US\$ 5.1 mil millones (Afoakwa, 2014).

El cacao se cultiva principalmente en África Occidental, América Central y del Sur, y el Sudeste de Asia. La región de África representa aproximadamente el 75% de las exportaciones mundiales de cacao, Asia y Oceanía representan el 16%, y las Américas representan el 6%. Los países con mayor producción de cacao son Costa de Marfil, Ghana, Indonesia, Nigeria, Camerún, Brasil, Ecuador y Malasia. Costa de Marfil es el mayor exportador mundial de cacao, representando el 37% de las exportaciones netas mundiales, seguido de Ghana con un 22% e Indonesia con un 15% (Afoakwa, 2014). En la Figura 10, se muestra un esquema de los principales países productores de cacao en el mundo.



**Figura 10.** Esquema de los principales países productores de cacao en el mundo. Adaptado de la ICCO 2008. Informe Anual 2006/2007. Organización Internacional del Cacao.

Fuente: Afoakwa, 2014.

El resto de países productores de cacao más notables son Bolivia, Colombia, Perú, República Dominicana, y Venezuela. En el 2012, los cultivos de cacao en el Perú se establecen como el segundo cultivo con mayor superficie agrícola de acuerdo al Censo Agropecuario (INEI, 2012) (Gómez et al., 2014). Los principales países de exportación de cacao peruano son Suiza, Francia, Holanda, Venezuela, Reino Unido, Italia, Estados Unidos y Alemania (Viera, 2017).

La producción de cacao en Piura se concentra en la provincia de Huancabamba, Morropón y Piura. El tipo de cacao que se produce mayormente es el cacao blanco o porcelana. García (2010) presenta fichas informativas de 73 cultivos de las principales zonas de producción de cacao en el Perú. El cacao blanco piurano, cuyo nombre varietal es porcelana, pertenece al grupo genético Forastero Alto Amazonas Raza Nativa-Piura (Moscol et al., 2012).

### 1.2.1 Descripción de la planta

El árbol de cacao es una planta originaria de la Selva Amazónica en América del Sur, cuyo nombre científico es “*Theobroma cacao* L” que pertenece al género “*Theobroma*”. El nombre genérico “*Theobroma*” se deriva del griego y significa "alimento de los dioses" y la palabra “cacao” deriva del nahua “cacáhua” (Gutiérrez, 2011).

La planta de cacao es un árbol pequeño, de 4 a 8 metros de altura, que puede alcanzar hasta 10 metros de altura con buena sombra (ver Figura 11). Su altura ideal es, aproximadamente, 400 msnm. Para su crecimiento, el terreno debe ser rico en nitrógeno y potasio, y el clima húmedo con una temperatura entre los 20-30 °C (Afoakwa, 2014).



**Figura 11.** Árbol de cacao de Piura.

Fuente: Laboratorio de Sistemas Automáticos de Control. Universidad de Piura. Perú.

El fruto o mazorca es de forma ovoide o elipsoidal, y alcanza hasta 15 - 30 cm de longitud y 8 - 10 cm de ancho, su cascara tiene 10 - 15 mm de espesor. El fruto maduro contiene entre 30 a 50 granos, unidos a una placenta central, y recubiertos por un mucilago blanquecino dulce y ácido, como se observa en la Figura 12. Este mucílago o pulpa se compone de 80 a 90% de agua, 2.7% de pentosas, 6-13% de azúcares fermentables, ácido cítrico de 0.5 a 1% y pequeñas cantidades de ácido aspártico, asparagina y ácido glutámico. El pH varía de 3 a 3.5 (Afoakwa et al., 2013).



**Figura 12.** Frutos de cacao, distribución de las semillas en placentación axial.  
Fuente: Alas & Morales, 2015.

La mazorca de cacao blanco Piurano (ver Figura 13), presenta la siguiente descripción morfológica (Moscol et al., 2012):

- Color al estado inmaduro: verde oscuro
- Forma básica: elíptico; oblongo
- Forma del ápice: atenuado; agudo
- Rugosidad: ligera
- Constricción basal: ligera; ausente
- Grosor de cáscara: variable
- Separación de un par de lomos: intermedia; ligera
- Profundidad de surcos: superficial; intermedia
- Forma en sección longitudinal: elíptica; ovada.
- Forma en sección transversal: aplanada; intermedia
- Color de cotiledones: morado y blanco; blanco



**Figura 13.** Fruto del cacao de Piura.

Fuente: Laboratorio de Sistemas Automáticos de Control. Universidad de Piura. Perú.

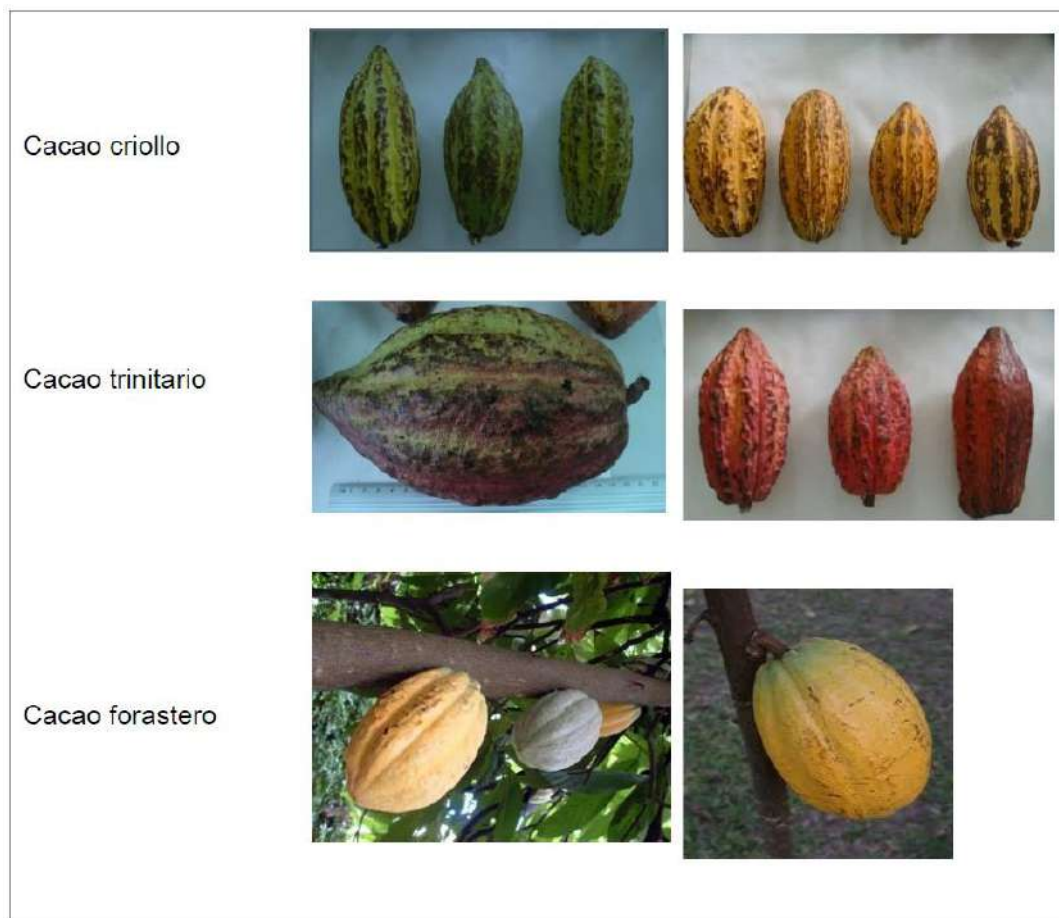
### 1.2.1.1 Variedades de cacao

Los principales tipos de cacao son: Forastero, Criollo, Trinitario y Nacional (ver Figura 14). Sin embargo, el grupo Forastero abarca una alta variabilidad genética, mientras que las formas Criollo son más estrechamente definidas (Gutiérrez, 2011; Afoakwa, 2014). Las características principales de las diferentes variedades de cacao se presentan en la Tabla 2.

- Forastero: Forastero significa "extranjero" y se refiere a cualquier árbol de cacao que no sea Criollo o híbrido. Generalmente producen granos de color púrpura y son nativos de la región amazónica (África occidental y sudeste asiático), y constituye el 95% de la producción mundial de cacao. Las mazorcas maduras son duras, amarillas, redondeadas y contienen 30 granos aproximadamente. Los granos de cacao Forastero se caracterizan por tener cotiledones amargos de color marrón oscuro. Esta variedad generalmente tiene mejor rendimiento y es menos susceptible a enfermedades que la variedad Criollo (Afoakwa, 2010).
- Criollo: Esta variedad proviene de Centroamérica, Colombia y Venezuela. Tiene un bajo rendimiento y una alta susceptibilidad a enfermedades, por lo cual es menos cultivado (Afoakwa, 2010). Se encuentra en Venezuela, América Central, Madagascar, Sri Lanka y Samoa (Fowler, 2009). Los granos son de color blanco a violeta, y tienen un sabor menos amargo y más aromático que el resto de variedades de cacao. La mazorca es de cáscara fina y poco aromática, larga de color amarillo o rojo, con surcos profundos y contienen de 20 a 30 granos aproximadamente. Esta variedad representa aproximadamente el 10% de la producción mundial (Gutiérrez, 2011).
- Trinitario: Esta variedad es un híbrido entre las variedades Criollo y Forastero, aunque su calidad es más próxima a la del Forastero. Proviene de Trinidad, pero se extendió a Venezuela, Ecuador, Camerún, Samoa, Sri Lanka, Java y Papua Nueva Guinea. Esta variedad es de mejor calidad que el Criollo, y de mayor rendimiento y menos sensibles a las enfermedades que el Forastero (Afoakwa, 2010).
- Nacional: Esta variedad proviene de la zona amazónica de Ecuador y tiene un aroma distintivo (Fowler, 2009; Afoakwa, 2010). Contribuye con cerca 5% de la producción mundial de cacao.

En Perú, la clasificación comercial del cacao tiene dos categorías: cacao fino o de aroma (Criollos y Trinitarios), y cacao ordinario (Forastero). En la zona de Buenos Aires, predomina la variedad de cacao criollo, siendo el porcentaje de cacao de almendra "blanca" de 40%.





**Figura 14.** Cacao criollo, trinitario y forastero.  
Fuente: Alas & Morales, 2015.

**Tabla 2.** Características de las diferentes variedades de cacao.

Características		Criollo	Forastero	Trinitario
Mazorca	Textura	Suave	Dura, Suave	Mayormente dura
	Color	Rojo	Verde	Variable
Granos	Promedio de granos	20 a 30	30 a más	30 a más
	Color de cotiledones	Blanco	Purpura	Variable; blanco
Agronómico	Vigor	Baja	Vigoroso	Intermedio
Calidad	Sensibilidad a plagas y enfermedades	Susceptible	Moderado	Intermedio
	Días de fermentación	1 a 3 días máximo	Normalmente 5 días	4 a 5 días
	Sabor	Chocolate débil	Buen chocolate	Buen chocolate
	Contenido de grasa	Baja	Alta	Media

Fuente: Afoakwa, 2014.

### 1.2.2 Beneficio o tratamiento postcosecha

Se denomina beneficio del cacao al conjunto de técnicas que influyen en la transformación biológica de los granos de cacao después de su cosecha. Para producir la mejor calidad de cacao, se debe realizar cada una de las fases del tratamiento de postcosecha correctamente. Además de la información obtenida de los trabajadores de la asociación ASPROBO (ver Figura 15), se tomó como referencia los documentos “Manual de Procedimientos de Cosecha y Acopio de Cacao, en el distrito de Buenos Aires, Morropón” y “Procedimientos validados para las buenas prácticas de beneficio de cacao”, para definir los procesos en la producción de cacao. En ambos documentos se hace uso de Normas Técnicas Peruanas para la producción de cacao.

La calidad final del grano de cacao, en cuanto a sabor y aroma, es influenciada por diversos aspectos importantes como el tipo del cacao, condiciones ambientales, y el tratamiento postcosecha. Este último aspecto es el más importante e influyente en las características organolépticas del cacao, y consiste principalmente en los procesos de fermentación y secado (Viera, 2017).



**Figura 15.** Asociación ASPROBO.  
Fuente: Viera, 2017.

#### 1.2.2.1 Cosecha

La cosecha consiste en retirar cuidadosamente las mazorcas de los árboles teniendo en cuenta la madurez de las mazorcas que se relaciona con su color externo. La naturaleza del cambio de color externo depende de la variedad del cacao (Afoakwa, 2010). Cuando no es visible el cambio en el color de la mazorca, se golpea mazorca con los dedos. Si el sonido es hueco, se concluye que el fruto está maduro (Amores et al., 2009).

Sólo las mazorcas maduras (no dañadas o infectadas) se cosechan. Tampoco se cosechan frutos sobremaduros porque sus granos están pregerminados y al desprenderse la radícula, ingresan insectos u hongos (Moscol et al., 2012). La cosecha se desarrolla utilizando herramientas adecuadas según la ubicación de la mazorca, por ejemplo si está ubicada en la parte baja de la planta, se usa un machete, y si está en la parte alta, se usa una desgarradora (Afoakwa, 2014). En la Figura 16, se muestran frutos de cacao cosechados en Morropón, Piura.

En los documentos “Manual de Procedimientos de Cosecha y Acopio de Cacao, en el distrito de Buenos Aires-Morropón” y “Procedimientos validados para las buenas prácticas de beneficio de cacao”, se menciona que la frecuencia de cosecha varía según la época de producción. En la zona de Buenos Aires, la época de mayor producción es durante los meses de Enero a Julio, y la cosecha se realiza con una frecuencia de 7 y 10 días. La época de menor producción es durante los meses de Agosto a Noviembre, y la cosecha se realiza con una frecuencia de 15 días.



**Figura 16.** Proceso de cosecha de frutos de cacao en Buenos Aires-Morropón, Piura.  
Fuente: Laboratorio de Sistemas Automáticos de Control. Universidad de Piura. Perú.

#### **1.2.2.2 Apertura**

La apertura de las mazorcas consiste en abrir las mazorcas maduras para extraer los granos utilizando un mazo o un machete, después los granos se sacan cuidadosamente con los dedos o con paletillas de madera o bambú, como se observa en la Figura 17. Al cortar las mazorcas se debe tener cuidado de no dañar las mazorcas pues esto ocasionaría el ataque de hongos y de insectos (Amores et al., 2009; Afoakwa, 2014).

Los granos extraídos se colocan en recipientes de madera o plásticos, pero no se deben poner en contacto con metales, y el tiempo transcurrido entre el desgrane y la puesta en fermentación debe ser máximo de un día. Algunos agricultores almacenan sus mazorcas cosechadas sin abrir durante 5 a 10 días, lo que se denomina como tiempo de aguante. En algunos casos este tiempo es utilizado para acumular las mazorcas suficientes para la fermentación o ayudar al desarrollo de procesos bioquímicos en los granos de cacao para mejorar su calidad.





**Figura 17.** (a) Proceso de apertura de frutos de cacao en Buenos Aires-Morropón, Piura.  
(b) Granos de cacao con mucilago o “baba”.


Fuente: Laboratorio de Sistemas Automáticos de Control. Universidad de Piura. Perú.

Los grados Brix representan el contenido de azúcar en los frutos. Según “Manual de Procedimientos de Cosecha y Acopio de Cacao, en el distrito de Buenos Aires-Morropón”, el cacao de la zona de Buenos Aires presenta los siguientes resultados:

- Un fruto de cacao maduro de la variedad criolla que se quiebra el mismo día de la cosecha, contiene un promedio de 24.6% de grado Brix.
- Un fruto de cacao maduro que se quiebra el tercer día de la cosecha, contiene un promedio de 19.8% de grado Brix.
- Un fruto de cacao maduro que se quiebra el quinto día de la cosecha, contiene un promedio de 19.6% de grado Brix.

### **1.2.2.3 Fermentación**

La fermentación consiste en una transformación bioquímica que influye en la calidad de los granos de cacao y consta de dos fases: anaeróbica (ausencia de oxígeno) y aeróbica. En esta transformación se da la degradación de la mayor parte de la pulpa o baba (mucílago azucarado) que rodea los granos de cacao y principalmente, la muerte del embrión, la transformación de los cotiledones y la formación de las sustancias precursoras del sabor y aroma a chocolate. Los granos sin fermentar son amargos y astringentes, y solo se utilizan en la producción de manteca (Amores et al., 2009; Afoakwa, 2014). Los cambios químicos principales en un grano de cacao durante la fermentación se muestran en la Figura 18.



**Figura 18.** Cambios químicos dentro de un grano de cacao durante la fermentación.  
Fuente: Fowler, 2009.

Diferentes técnicas de fermentación han sido desarrolladas, las más comunes son: ruma o monte de fermentado, caja de fermentación, caja de fermentación tipo escalera, cesta de fermentación y bandeja de fermentación; pero los mejores resultados se obtienen con las cajas de fermentación de madera, como la que se observa en la Figura 19.



**Figura 19.** Caja de fermentación de madera.  
Fuente: Viera, 2017.

La fermentación dura entre 3 a 8 días dependiendo de las condiciones ambientales, método de fermentación, cantidad a fermentar y el tipo de cacao. El tiempo de fermentación está relacionado con la cantidad de pulpa y la concentración de polifenoles. El tiempo es mayor si la intensidad del color violeta de los cotiledones es mayor, esta intensidad depende de la concentración de antocianina. El grano criollo fermenta de 3 a 4 días, el trinitario fermenta entre 5 a 6 días y el Forastero, de 5 a 8 días. Durante este proceso el grano de cacao es removido de un contenedor a otro (ver Figura 20), para que ingrese oxígeno y favorecer la fermentación aeróbica (Amores et al., 2009).



**Figura 20.** Remoción en caja de fermentación de madera.

Fuente: Viera, 2017.

Durante la fermentación, la temperatura puede alcanzar los 50° C, mientras más cerca se encuentre a esa temperatura, mejor resulta la calidad del cacao seco. Al finalizar la fermentación, el embrión desaparece, los granos se hinchan considerablemente, la temperatura disminuye hasta llegar a la temperatura ambiental y la humedad también disminuye. El grado de fermentación se puede determinar a través del corte de algunos granos. Mientras que los granos fermentados tienen una coloración café-violácea, los no fermentados son violetas y color pizarra por dentro.

La asociación ASPROBO usa cajas de fermentación de madera de aproximadamente 1m<sup>3</sup> con un grosor de 3 a 4 cm y elaboradas a base de madera tipo tornillo, tienen agujeros para facilitar el drenaje y la ventilación. Este tipo de fermentador es el más usado debido a la facilidad de su construcción, los buenos resultados que se obtienen y además evita que por las noches tenga caídas significativas de temperatura. También se tapan los granos con hojas de plátano y sacos negros de yute para mantener la temperatura. Las desventajas de este tipo de fermentadores, es la dificultad para remover la masa y la presencia de microflora que causa olores desagradables en los granos del cacao. En ASPROBO, la fermentación se realiza en una sala completamente cerrada, cuyas paredes son de material noble (ladrillo) y están cubiertas con capas de material aislante (tecnopor), para mantener una temperatura mayor a la temperatura ambiente (ver Figura 21). El proceso de fermentación dura de 6 a 8 días con remociones de masa después de 48 horas que se colocaron los granos a fermentar (fermentación aeróbica) y cada 24 horas pasada la primera remoción.



**Figura 21.** Sala de fermentación de ASPROBO.

Fuente: Viera, 2017.

#### 1.2.2.4 Secado

Después de la fermentación, el contenido de humedad de los granos debe reducirse de 55-60% a 7-8%, considerado un contenido de humedad adecuado para el almacenamiento seguro de cacao evitando el crecimiento de hongos y ataque de insectos.

En el proceso de secado se continúa algunos de los cambios químicos iniciados en la fermentación para reducir el amargor y la astringencia, y también el desarrollo del color marrón característico del grano de cacao (Afoakwa, 2014).

El secado puede ser natural colocando los granos de cacao sobre superficies de madera o cemento bajo el sol, de tal manera que forman una capa lo más delgada posible, como se observa en la Figura 22. Es recomendable un secado lento con el fin de favorecer los cambios químicos como lo son las reacciones de oxidación, se remueve cada cierto tiempo para distribuir uniformemente el calor y así conservar la calidad del grano. Los granos deben removerse con rastrillos de madera en camellones. Este tipo de secado dura aproximadamente una semana. También existe un secado artificial utilizado cuando el clima es húmedo y menos soleado (Afoakwa, 2014; Gómez et al., 2014). Un ejemplo de este tipo de secado es el que utiliza secadores eléctricos o a gas propano, que secan a una temperatura máxima de 45 °C. Si los granos de cacao se exponen a temperaturas muy altas o a un secado más rápido, estos resultan con un sabor ácido y amargo. Si en el secado se utiliza fuego a leña, los granos resultan con sabor ahumado.



**Figura 22.** Proceso de secado de granos de cacao en ASPROBO.

Fuente: Viera, 2017.

#### 1.2.2.5 Selección

En general, la calidad es un conjunto de especificaciones que se deben cumplir dentro de las tolerancias o límites dados (Afoakwa, 2014). Actualmente existe una mayor demanda de granos de cacao; pero también, existe una mayor exigencia en su calidad que se define por sus características físicas, químicas, y sensoriales vinculadas con el sabor y el aroma. Los granos deben ser bien fermentados, pues de lo contrario los granos son ácidos, astringentes y sin aroma, deben estar libre de moho o sabores desagradables, tener tamaños uniformes, en promedio pesar 1 gramo, y estar libre de insectos o residuos. También deben tener un contenido de humedad entre 6 y 8%, un contenido libre de ácidos grasos, menor al 1%, el contenido de manteca de cacao de 50 a 58%, el contenido de la cáscara de menos de 11 a 12%.

En los países productores de cacao, la clasificación del grano se realiza visualmente a través de una prueba de corte, en ocasiones complementada con una degustación. La prueba de corte (ver Figura 23) revela la presencia de granos defectuosos en el lote y el grado de fermentación de los granos, que tiene una gran influencia en el sabor y la calidad de los granos. Según la Organización Internacional de Normalización (ISO), un mínimo de 300 granos deben ser analizados por cada tonelada de cacao, y con un mínimo de 30% de los sacos de cacao se determina el grado (Afoakwa, 2014).



**Figura 23.** Prueba de corte de granos de cacao.  
Fuente: Viera, 2017.

A continuación en la Tabla 3 se presentan las distintas características de los granos secos bien fermentados, y los secos mal fermentados.

**Tabla 3.** Características de los granos secos bien fermentados, y los mal fermentados.

Grano seco fermentado	Grano seco sin fermentar o mal fermentado
Hinchado o grueso	Más bien aplanado
La cáscara se separa fácilmente	Por lo general es difícil separar la cáscara
Color marrón o chocolate	Color violáceo en su interior o blanquecino
Naturaleza quebradiza	Naturaleza compacta
Sabor medianamente amargo	Sabor astringente
Aroma agradable	Aroma desagradable

Fuente: Viera, 2017.

En ASPROBO, para la clasificación de los granos según su tamaño, se utiliza una zaranda con malla metálica de 1/4 pulg, mostrada en la Figura 24. También se eliminan las impurezas y se escogen los granos defectuosos, como se observa en la Figura 25.





**Figura 24.** Máquina de selección de granos de cacao según su tamaño.  
Fuente: Viera, 2017.



**Figura 25.** Proceso de selección de granos de cacao según su tamaño.  
Fuente: Viera, 2017.

El almacenamiento de los granos de cacao debe ser el adecuado para evitar la re-humidificación, y la aparición de moho y olores fuertes. El ambiente del almacenamiento debe ser bien ventilado, iluminado, cerrado, no debe tener el piso húmedo, y alejado de productos con olores fuertes. Los granos de cacao bien fermentados y secados se puede almacenar por un período de 5 a 6 meses (Amores et al., 2009; Gómez et al., 2014). En la Figura 26, se presenta el almacenamiento de granos de cacao en la asociación ASPROBO.



**Figura 26.** Almacenamiento de granos de cacao en sacos.  
Fuente: Viera, 2017

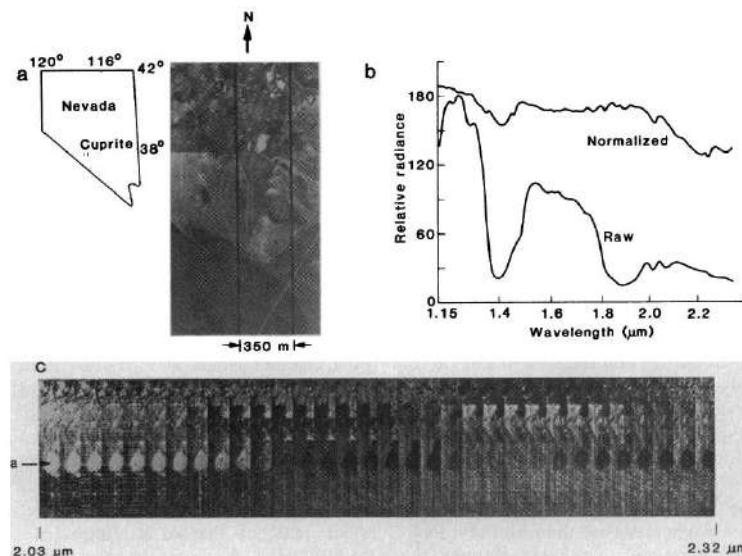
## Capítulo 2

### Visión Hiperspectral

#### 2.1 Fundamentos de la imagen hiperspectral

Con el fin de comprender mejor la técnica de imágenes hiperspectrales, se presenta una breve introducción de la teoría en la que se basa. Por lo tanto, se proporcionará algunos principios fundamentales de la técnica de imágenes hiperspectrales. Además, se presentan algunos conceptos básicos como es el espectro electromagnético, firma espectral, librerías espectrales, resolución espectral y espacial.

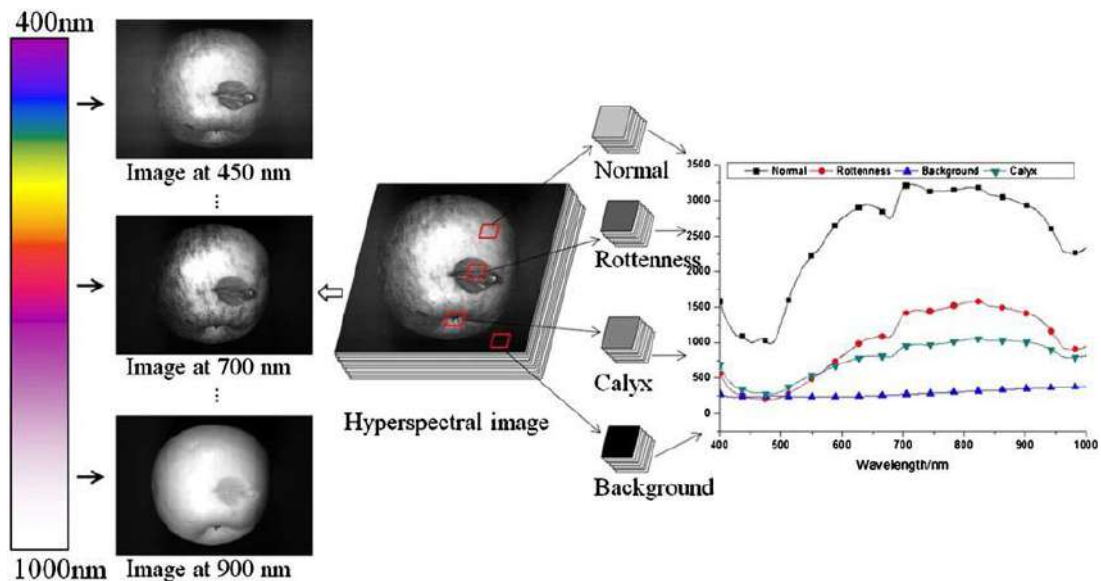
El término "imagen hiperspectral" fue utilizado por primera vez por (Goetz et al., 1985) para aplicaciones de teledetección, como se observa en la Figura 27. La teledetección es la técnica que por medio de imágenes digitales nos permite obtener información de los objetos situados sobre la superficie terrestre.



**Figura 27.** (a) Foto aérea del distrito minero de Cuprite en Nevada. (b) Espectros derivados de un área de 5 por 5 píxeles. (c) Un conjunto de 32 imágenes espectrales tomadas a intervalos de 9.3 nm entre 2.03 y 2.32 μm.

Fuente: Goetz et al., 1985.

La imagen hiperespectral, conocida también como espectroscopia de imagen, espectrometría de imagen, e imagen química o espectroscópica; es una técnica emergente que combina las ventajas de la visión por ordenador tradicional y la espectroscopia para obtener información espacial (localización) y espectral (identificación) de un objeto simultáneamente. La respuesta de la materia a la luz (onda electromagnética) proporciona un espectro unidimensional en cada píxel (Pu et al., 2015). Una vista conceptual de una imagen hiperespectral se presenta en la Figura 28.



**Figura 28.** Vista conceptual de una imagen hiperespectral de una manzana con podredumbre.

Fuente: Zhang et al., 2014.

### 2.1.1 Fundamentos de la visión artificial

La visión artificial o visión por computador, es una rama de la inteligencia artificial. Los sistemas automáticos de visión por computador simulan el proceso del sentido de la visión, mediante el análisis e interpretación de los objetos en una imagen adquirida.


El crecimiento continuo de aplicaciones relacionadas a la visión artificial se debe al desarrollo de los lenguajes de programación y sistemas operativos. Entre las aplicaciones más comunes se encuentran: detección y seguimiento de objetos, análisis de terrenos, análisis de imágenes satelitales y médicas, autenticación, inspección industrial automatizada, navegación de robots móviles, reconocimiento de rostros y huellas dactilares, control de calidad de productos, etc.

Con la visión artificial, las características de objetos como tamaño, forma, color, textura superficial, y defectos externos pueden ser evaluados fácilmente pero presenta limitaciones al discriminar objetos de colores similares, realizar clasificaciones complejas, determinar propiedades internas como la composición química, entre otros (Viera, 2017).



### 2.1.1.1 Procesamiento

Cuando se da la formación de la imagen digital, es común la presencia de ruido o interferencias que degraden la imagen, por ello se aplican técnicas de mejora de imagen digital. Algunas de las técnicas de mejora más comunes son disminuir el ruido, modificar el contraste de la imagen, ajustar el brillo, suavizar o realzar bordes, modificar el enfoque, etc. Un ejemplo de procesamiento de imágenes se presenta en la Figura 29.



**Figura 29.** Eliminación del ruido de impulsos mediante filtrado medio: (a) imagen espectral de una muestra de huevo con ruido; (b) imagen filtrada de la imagen (a).

Fuente: Ngadi & Liu, 2010.

Los métodos de mejora de imágenes se dividen en dos categorías: dominio espacial y dominio frecuencial. Se pueden combinar las dos categorías anteriores en el procesamiento de una imagen digital (González & Woods, 2002).


- Los métodos en el dominio espacial se aplican al propio plano de la imagen, estos consisten en la manipulación directa de los píxeles de una imagen. Dos categorías principales de estos métodos son las transformaciones de intensidad que operan en los píxeles individuales y filtrado espacial que opera en las vecindades de píxeles pertenecientes a la imagen.
- Los métodos en el dominio frecuencial se aplican en la transformada de Fourier de una imagen, en lugar de la propia imagen.

Muchas técnicas de procesamiento digital de imágenes son capaces de analizar imágenes multidimensionales como las imágenes hiperespectrales.

#### a) Morfología

La morfología matemática es una técnica para extraer elementos de la imagen que representan y describen la forma de la región, tales como bordes, límites, esqueletos, etc. Las operaciones morfológicas binarias son las operaciones de deslizamiento de un elemento estructurante sobre la imagen. La forma y el tamaño escogido del elemento estructurante depende de los objetos a analizar.

Hay dos operaciones morfológicas principales: dilatación y erosión. La dilatación consiste en incorporar en un objeto todos los puntos de fondo que se conectan al objeto, y la erosión consiste en eliminar todos los puntos de contorno del objeto, estos puntos son píxeles que se encuentran en el objeto, pero tiene al menos un píxel vecino fuera del objeto. La dilatación reduce las diferencias entre dos objetos separados y la erosión elimina detalles demasiado pequeños. Otras operaciones morfológicas se muestran en la Figura 30, como relleno de región, máscara convexa, esqueleto de una región, translación, reflexión, complemento de una región, diferencia, apertura, cierre, transformada Acierto-o-Fracaso, extracción de límites, adelgazamiento, espesamiento.



**Figura 30.** a) Cierre morfológico; b) Cierre por reconstrucción; c) Imagen pancromática VHR original; d) Apertura por reconstrucción; e) Apertura morfológica.


Fuente: Ngadi & Liu, 2010.

#### b) Histograma

El histograma de la imagen en escala de grises es la frecuencia relativa de aparición de cada nivel de gris en la imagen. El histograma de una imagen digital con niveles de intensidad en el rango  $[0, L - 1]$  se define como una función discreta  $h(r_k) = n_k$ , donde  $r_k$  es el valor de la intensidad de orden  $k$  y  $n_k$  es el número de píxeles de la imagen con intensidad  $r_k$  (González & Woods, 2002). El proceso de ecualización del histograma consiste en redistribuir los niveles de gris de la imagen por la reasignación de los valores de brillo de los píxeles. Uno de los principales problemas en la ecualización de histograma es la presencia de ruido, pues aumenta el contraste y distorsiona la imagen. En la Figura 31, se muestra la ecualización de un histograma.


#### c) Filtro

Un filtro es un conjunto de operaciones donde el valor de un píxel depende de su anterior valor y el de los píxeles vecinos. No se modifica la geometría de la imagen resultante. El filtro consiste en una función de transferencia que al aplicarse a una señal de entrada, se obtiene una señal de salida según lo que se necesita. Los filtros se clasifican en: filtro paso bajo, filtro pasa alto y filtro pasa banda. También se clasifican según el dominio de trabajo: filtros en el dominio del espacio y filtros en el dominio de la frecuencia. Los principales usos de los filtros son suavizar la imagen al uniformizar la intensidad de los píxeles vecinos, realzar la imagen al aumentar los niveles de intensidad, eliminar ruido y detectar bordes. Un ejemplo de filtrado de imágenes se muestra en la Figura 32.



**Figura 31.** Mejora de la calidad de imagen mediante ecualización de histograma: (a) imagen espectral de una muestra de cerdo; (b) histograma de la imagen en (a); (c) imagen resultante obtenida de la imagen (a) por ecualización de histograma; (d) histograma de la imagen en (c).

Fuente: Ngadi & Liu, 2010.



**Figura 32.** Afilado de imágenes utilizando un laplaciano de Gauss: (a) imagen espectral de una muestra de cerdo; (b) imagen filtrada de la imagen (a) por una operación de LoG.

Fuente: Ngadi & Liu, 2010.

### 2.1.1.2 Segmentación


La segmentación es la etapa donde la imagen de entrada se separa en cada uno de los elementos que la integran. La mayoría de los métodos de segmentación se basan en propiedades de intensidad como la similitud (referida a las regiones) y la discontinuidad (referida a los bordes). Algunas técnicas de segmentación son:

- Segmentación por umbralización (“thresholding”).
- Segmentación por homogeneidad: algoritmo de crecimiento de regiones y la segmentación por División y Fusión (“Split & Merge”).
- Segmentación basada en bordes: Roberts, Prewitt y Sobel.
- Segmentación basada en modelos.

### 2.1.2 Fundamentos de la espectroscopia


El término "espectroscopia" proviene del latín “espectro” (apariciencia, imagen) y griego “skopia” (ver). La espectroscopia es la ciencia que estudia las interacciones entre la radiación electromagnética y la materia, para proporcionar información química y física, cualitativa y cuantitativa, de la materia (ElMasry & Sun, 2010). Este fenómeno es explicado por la ley de Beer-Lambert, que indica que hay una relación entre la luz absorbida y la concentración de una sustancia a una determinada longitud de onda (Travers, 2013).

El origen de la técnica espectrométrica se da en 1665, cuando Isaac Newton describió el concepto de dispersión de la luz y el sistema optomecánico de un espectrómetro (ver Figura 33). Newton descubrió que cuando un haz de luz del sol pasa a través de un prisma de cristal, el haz que emerge de la luz consiste en un espectro continuo de colores (González & Woods, 2002).



**Figura 33.** Espectro de color que se ve haciendo pasar luz blanca a través de un prisma.  
Fuente: González & Woods, 2002.

El análisis espectral estudia la luz en función de la longitud de onda que ha sido absorbida, reflejada o transmitida de un material. A medida que los fotones entran en la materia, algunos son reflejados desde las superficies, otros pasan y otros son absorbidos. Los fotones reflejados desde la superficie o refractados por moléculas dentro de la materia están dispersos y pueden ser detectados. A nivel molecular, la dispersión o absorción de la luz depende de los enlaces atómicos o de la estructura molecular de la molécula interceptora. Cada objeto biológico tiene propiedades ópticas especiales, es decir, que tiene un patrón de espectros único que indica su composición química como sus propiedades físicas y estructurales (ElMasry & Sun, 2010; Munawar, 2014). Algunos espectros reflectantes difusos de productos agrícolas se muestran en la Figura 34.



**Figura 34.** Espectros reflectantes difusos típicos de algunos productos agrícolas.

Fuente: Munawar, 2014.

El espectro infrarrojo comúnmente se divide en tres regiones denominadas infrarrojo cercano, medio y lejano. Las radiaciones infrarrojas cercanas (NIR) cubren la gama del espectro electromagnético entre 750 y 2500 nm (Bureau, 2009). Las bandas de absorción observadas en el rango espectral NIR surgen de armónicos y bandas de combinación de vibraciones de estiramiento y flexión de O-H (humedad, carbohidratos y grasas), N-H (proteínas y aminoácidos), C-H (compuestos orgánicos y derivados de petróleo) y S-H que permiten la evaluación de las características químicas y físicas (ElMasry & Sun, 2010).

Durante los últimos años, la espectroscopia infrarroja cercana (NIRS) se ha convertido en uno de los métodos de análisis no destructivos más utilizados en muchas áreas, principalmente en la industria alimentaria (Bureau, 2009). La principal desventaja de la espectroscopia NIR es que proporciona un espectro medio de una muestra sin tener en cuenta la distribución espacial de los componentes. La falta de información espacial hace que la espectroscopia sea menos lenta y más apropiada para las aplicaciones en tiempo real que la imagen hiperespectral.

### 2.1.3 Espectro electromagnético

La luz es una onda no material compuesta de campos eléctricos y magnéticos oscilantes y, puede viajar a través del vacío sin la ayuda de una sustancia material (medio). La luz tiene una naturaleza dual, posee una naturaleza ondulatoria y un comportamiento similar a las partículas. La luz consiste en una corriente de partículas, llamadas fotones, que viajan a determinada velocidad y transportan una cantidad de energía proporcional a la frecuencia de la luz (ElMasry & Sun, 2010). Dependiendo de las circunstancias, cuando la luz se comporta como una onda, se caracteriza por una velocidad, longitud de onda y frecuencia; cuando se considera partículas, cada partícula tiene una energía relacionada con la frecuencia de la onda, dada por la siguiente relación de Planck:


$$E = hf$$

Dónde E es la energía del fotón, h es la constante de Planck ( $6.626 \times 10^{-34} \text{ J}\cdot\text{s}$ ), y f es la frecuencia.

La radiación electromagnética o energía electromagnética, es un fenómeno que toma la forma ondulatoria propagada en el vacío o en la materia. Consta de componentes de campo eléctrico y magnético que oscilan en fase perpendicular entre sí y perpendicular a la dirección de propagación de energía. Esta radiación está conformada por fotones que tienen propiedades de ondas, carecen de carga y masa, y se mueven siempre a la velocidad de la luz. Cada tipo de radiación electromagnética tiene sus propios fotones (fotones de luz visible, de luz infrarroja, luz ultravioleta, de rayos X, etc.) (Terán & Viteri, 2005).

El espectro electromagnético, mostrado en la Figura 35, se compone de varias regiones, que incluyen los rayos gamma, los rayos X, la radiación ultravioleta (UV), la luz visible (VIS), la radiación infrarroja cercana (NIR), infrarrojo medio (MIR) e infrarrojo lejano (FIR), microondas y ondas de radio (FM y AM). No hay límites precisamente definidos y la división entre las bandas del espectro electromagnético es arbitraria (ElMasry & Sun, 2010; Travers, 2013).

La frecuencia ( $f$ ) de una onda electromagnética viene determinada por la frecuencia de la fuente. La velocidad de la luz en el vacío se aproxima a  $c = 3 \times 10^8 \text{ ms}^{-1}$ . En general, una onda electromagnética consta de canales y crestas sucesivas, y la distancia entre dos crestas adyacentes se denomina longitud de onda. La frecuencia ( $f$ ) es inversamente proporcional a la longitud de onda ( $\lambda$ ), de acuerdo con la ecuación de la velocidad de la onda ( $v$ ) que es igual a c en el vacío (ElMasry & Sun, 2010):  $v = f\lambda$



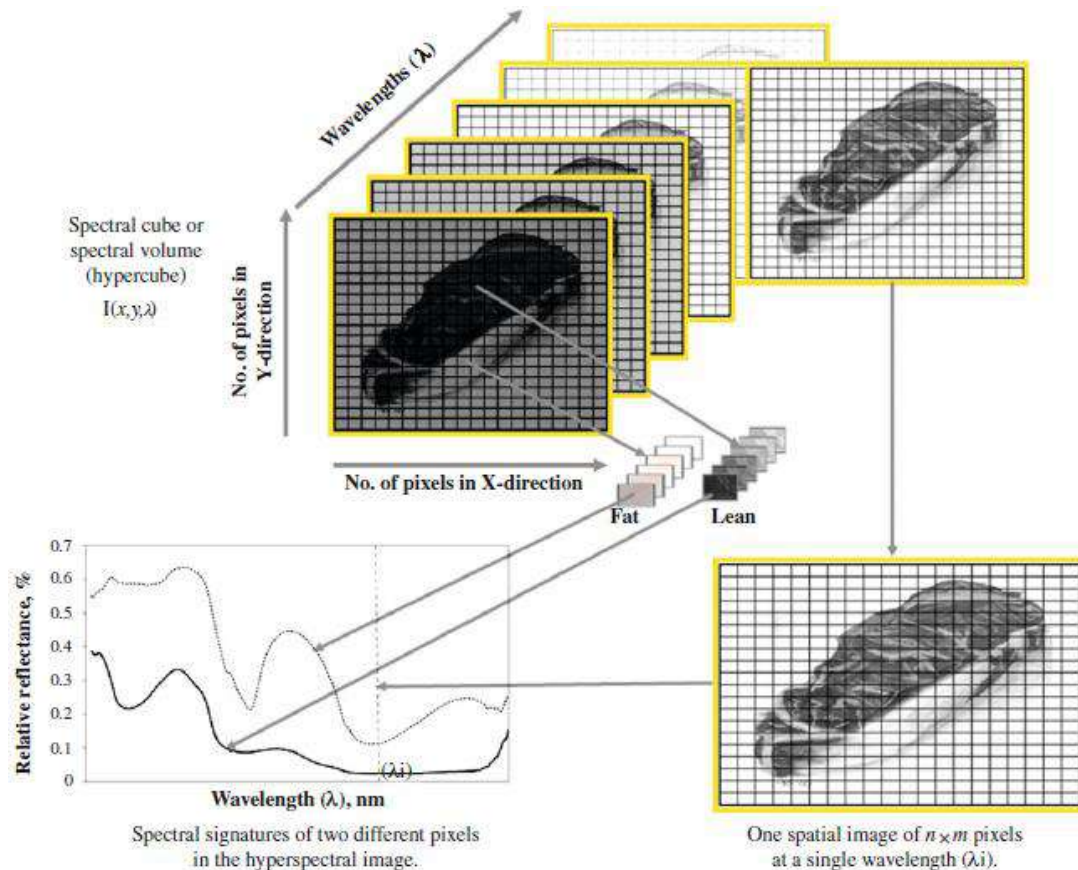
**Figura 35.** El espectro electromagnético. El espectro visible se muestra ampliado.  
Fuente: González & Woods, 2002.

#### 2.1.4 Conceptos básicos

Las imágenes digitales son bidimensionales, y con una nueva dimensión del "espectro", los datos de la imagen hiperespectral pueden ser representados como un cubo de datos tridimensional que se denomina como cubo hiperespectral tridimensional, hipercubo, datacubo, volumen de datos, cubo espectral o volumen espectral (ElMasry & Sun, 2010). El hipercubo se puede describir como imágenes bidimensionales ( $x, y$ ) en cada longitud de onda unidimensional ( $\lambda$ ) o como espectros ( $\lambda$ ) en cada pixel de imagen ( $x, y$ ). La imagen hiperespectral está compuesta por una serie de subimágenes espaciales contiguas ( $x, y$ ) en cada longitud de onda individual ( $\lambda$ ). Cada sub-imagen presenta la distribución espacial de la información espectral a cada longitud de onda. A una determinada longitud de onda, la intensidad espectral en diferentes lugares dentro de una imagen refleja la diferente absorción de luz (Gómez, 2010). En la Figura 36, se presenta un diagrama esquemático de la imagen hiperespectral.

La mayoría de veces los píxeles de una imagen espectral son mixtos o de mezcla, es decir que se encuentran diferentes materiales. Los píxeles puros son aquellos que representan un sólo tipo de material.





**Figura 36.** Diagrama esquemático de la imagen hiperespectral de un pedazo de carne.  
Fuente: ElMasry & Sun, 2010.

#### 2.1.4.1 Resolución espectral y espacial

La resolución espectral está relacionada con dos parámetros importantes que son el número de canales espectrales en los que el sensor adquiere datos y el ancho de las bandas espectrales correspondientes a dichos canales. Se obtiene una discriminación más fina al contar con un número alto de bandas y que estas a su vez, sean estrechas. Estos dos parámetros se definen según el tipo de aplicación en el que se trabaja.

La resolución espacial se define según el área que está representada por un píxel de imagen, es decir, se refiere al número de píxeles por unidad de longitud. La resolución espacial está determinada por el tamaño de píxeles de la cámara bidimensional y la lente objetivo (ElMasry & Sun, 2010).

#### 2.1.4.2 Firmas espectrales

Por la composición química y estructura física de distintos materiales, estos reflejan, dispersan, absorben y/o emiten energía electromagnética en patrones distintivos a longitudes de onda específicas. La firma espectral o huella digital espectral, o simplemente espectro., es el patrón de reflexión, absorbancia, transmitancia y/o emisión de energía electromagnética a longitudes de onda específicas (ElMasry & Sun, 2010).




### 2.1.4.3 Bibliotecas espectrales

Las bibliotecas espectrales son recopilaciones de espectros de reflectancia medidos a partir de materiales de composición conocida, usualmente en el campo o en el laboratorio. Varias bibliotecas espectrales de alta calidad están disponibles públicamente, entre las más conocidas se encuentran la Biblioteca espectral USGS y la biblioteca ASTER.

Los espectros de las bibliotecas se utilizan principalmente para comparar y analizar la información obtenida de sensores remotos, calibrar correctamente los elementos de sistemas de teledetección y comprobar el rendimiento de sistemas de teledetección.

### 2.1.4.4 Imágenes multispectrales

El campo de la imagen espectral se divide en tres técnicas llamadas multispectral, hiperespectral y ultraspectral, la diferencia entre ellas no se basa en el número de bandas. Los sistemas multispectrales tratan con varias imágenes en bandas discretas y estrechas, y los sistemas hiperespectrales tratan con imágenes en bandas estrechas en un rango de longitud de onda contiguo resultando en el “espectro” de todos los píxeles de la escena. La imagen ultrasensorial se usa en sistemas de imágenes espectrales con una resolución espectral muy fina. Estos sistemas suelen tener una baja resolución espacial de varios píxeles solamente (ElMasry & Sun, 2010). Las principales ventajas de los sistemas de imágenes multispectrales son el costo bajo en comparación con los sistemas hiperespectrales y el hecho de que pueden ser más específicos y beneficiosos en aplicaciones de tiempo real. Muchas veces, un sistema hiperespectral es utilizado para determinar el conjunto más apropiado de longitudes de onda que finalmente se utilizará en un sistema multispectral. En la Figura 37, se muestra una vista conceptual de una imagen multispectral.



**Figura 37.** Vista conceptual de una imagen multispectral de un melocotón con defectos.

Fuente: Zhang et al., 2014.

## **2.2 Configuración de sistema de visión hiperespectral**

La selección adecuada de los instrumentos, el buen diseño del sistema y su calibración son aspectos importantes en el buen rendimiento de los sistemas de imágenes hiperespectrales. Algunos instrumentos usados en la visión artificial convencional y la espectroscopia también se pueden utilizar en la visión hiperespectral. También existen instrumentos específicamente diseñados para la visión hiperespectral (Qin, 2010).

### **2.2.1 Modos de adquisición de imágenes hiperespectrales**

Para la construcción de un hipercubo se pueden utilizar diferentes modos de detección y escaneo. Estos modos de detección y escaneo se diferencian en la disposición y configuración de los elementos que constituyen el sistema de adquisición.

#### **2.2.1.1 Modo de detección**

Dependiendo de las propiedades o características que se quiera extraer de la muestra a analizar, existen tres modos de detección comunes para la formación de imágenes hiperespectrales: reflectancia, transmitancia e interacción. La disposición de la fuente de luz y el detector óptico (cámara, espectrógrafo y lente) varían según el modo de adquisición a utilizar (Wu & Sun, 2013).

##### **a) Reflectancia**

Este método consiste en que el detector captura la luz reflejada de la muestra iluminada en una conformación específica para evitar la reflexión especular, en algunos casos, para minimizar la reflectancia especular, la fuente de luz y el detector se colocan bajo un ángulo específico, comúnmente 45°. Este sistema es el más utilizado y de un coste relativamente bajo, comúnmente utilizado en el análisis de muestras sólidas y semisólidas. En el caso de la supervisión de la calidad de los alimentos, el modo de operación más utilizado es la reflectancia. Algunas aplicaciones de este método incluyen la determinación de los componentes químicos de frutos y la evaluación de características externas de frutos como color, tamaño, forma, textura superficial, y la presencia de defectos en la superficie (Wu & Sun, 2013).

##### **b) Transmitancia**

El detector se encuentra en el lado opuesto de la fuente de luz y capta la luz transmitida a través de la muestra. Este modo se utiliza para el análisis de sólidos de baja densidad, muestras líquidas y semilíquidas. Generalmente, no se utiliza para el análisis de alimentos. El modo de transmitancia tiene un nivel de señal bajo (atenuación de la luz) y es afectado por el grosor de la muestra, para compensar esta situación, se aumenta la intensidad de la luz pero esto puede causar un posible daño térmico del fruto y la alteración de las propiedades espectrales. Algunas aplicaciones de este modo incluyen la detección de daños por insectos, la concentración de componentes internos y detectar defectos internos de materiales relativamente transparentes (Wu & Sun, 2013).

### c) Interacción

La fuente de luz y el detector están situados en el mismo lado de la muestra y paralelos entre sí, de tal manera que la reflectancia especular no puede alcanzar directamente el detector. Por esta disposición, el modo de interacción reduce la influencia del espesor, presenta menos efectos de superficie en comparación con el modo de reflectancia y por lo tanto, detecta información más profunda en la muestra. Algunas aplicaciones de este modo incluyen la evaluación de la grasa en la carne, la detección de nematodos en pescados, la evaluación de la fracción de hielo en pescados y la evaluación de la frescura en pescados (Wu & Sun, 2013).

#### 2.2.1.2 *Modo de escaneo*

Hay tres formas convencionales de construir una imagen espectral: escaneo de área o plano, escaneo de puntos y escaneo de líneas (ver Figura 38). En el escaneo de puntos, la muestra se moviliza en las direcciones x e y punto por punto; mientras que en el caso de escaneo de líneas, lo hace línea por línea. En el escaneo de área, los datos se recogen con un detector bidimensional y se captura el campo de visión completo para cada longitud de onda individual, sin mover la muestra. Los métodos de escaneo de puntos y de exploración de líneas se denominan métodos de escaneo espacial, pues escanean la muestra en el dominio espacial moviendo la muestra, punto por punto o línea por línea, respectivamente, mientras que el escaneo de área es un método de escaneo espectral.

Los hipercubos obtenidos por escaneo de puntos, escaneo de líneas y escaneo de área se almacenan en los formatos de Banda intercalada por píxel (BIP), Banda intercalada por línea (BIL) y Banda secuencial (BSQ), respectivamente. Estos tres tipos de datos se pueden convertir entre sí. Los formatos BIP y BSQ son óptimos para el acceso espectral y espacial de los datos de imágenes hiperespectrales, respectivamente. El formato BIL presenta un compromiso de rendimiento entre el análisis espacial y espectral (ElMasry & Sun, 2010; Qin, 2010).

#### a) Escaneo de área

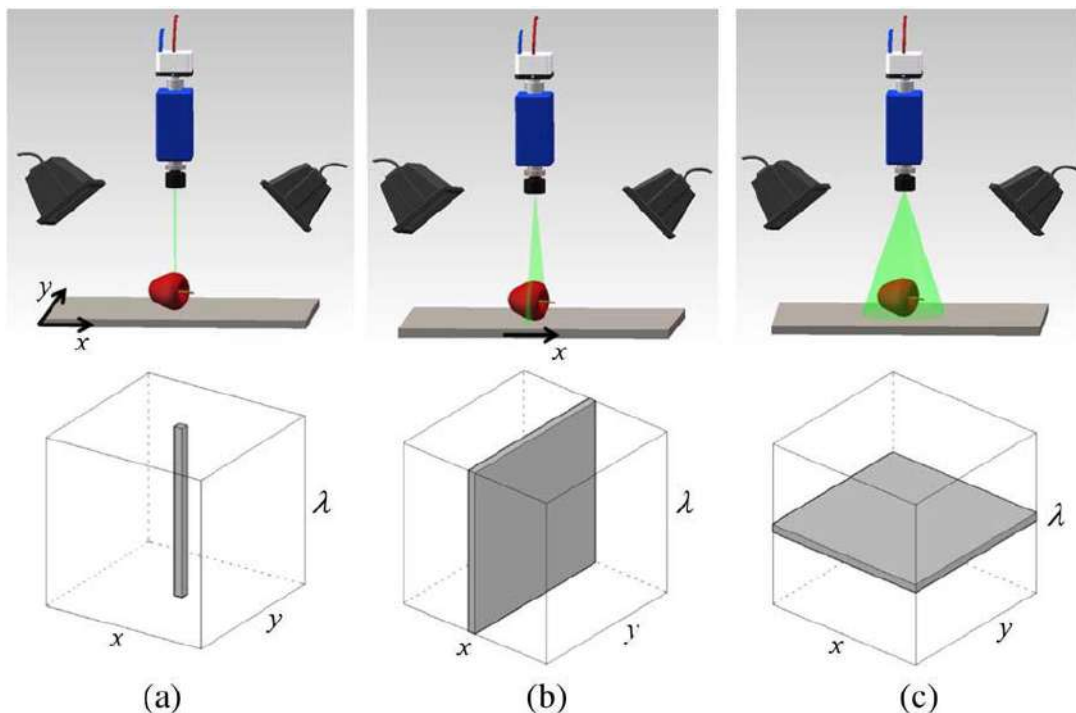
El método de escaneo de área también es conocido como visión de escaneo de plano focal o filtro sintonizable. Consiste en mantener fijo el campo de visión de la imagen y obtener imágenes de una longitud de onda después de otra, por lo que también se le conoce como método de escaneo de longitud de onda o método secuencial de banda. Para la adquisición de una imagen a diferentes longitudes de onda se requiere un filtro sintonizable. Este método es adecuada para muchas aplicaciones en las que no se requiere una muestra en movimiento y cuando el largo tiempo de adquisición no influye en el estado de la muestra (ElMasry & Sun, 2010; Qin, 2010).

b) Escaneo de puntos o “Whiskbroom”

El método de escaneo de puntos también es conocido como “Whiskbroom”. La imagen se crea con un escaneo doble: uno en el dominio de longitud de onda y otro en el dominio espacial. Consiste en adquirir el espectro de un solo punto a lo largo de dos dimensiones espaciales desplazando la muestra o el detector, y luego la muestra se mueve y se toma otro espectro formando así la imagen hiperespectral. Este diseño se usa comúnmente para la formación de imágenes microscópicas donde el tiempo de adquisición no suele ser un problema (ElMasry & Sun, 2010; Qin, 2010; García-Allende et al., 2011).

c) Escaneo de líneas o “Pushbroom”

El método de escaneo de líneas también es conocido como “Pushbroom”. Consiste en adquirir los espectros de líneas que son registrados simultáneamente por un detector de array. Este método puede considerarse una extensión del método de escaneo de puntos. Las imágenes hiperespectrales son adquiridas por un sistema dispersivo de longitud de onda que incorpora una rejilla o prisma de difracción. Normalmente, esta configuración se utiliza cuando la muestra está en movimiento, es particularmente adecuado para sistemas de cinta transportadora (ElMasry & Sun, 2010; Qin, 2010; García-Allende et al., 2011; Pu et al., 2015).




**Figura 38.** Tres diferentes modos de escaneo para generar una imagen hiperespectral.  
(a) Escaneo de puntos. b) Escaneo de línea. c) Escaneo de área.

Fuente: Zhang et al., 2014.

### 2.2.2 Principales componentes del sistema hiperspectral

La configuración de los sistemas de imágenes hiperspectrales varían según el objeto a analizar y la técnica de adquisición de la aplicación. Los componentes básicos para la construcción de sistemas de visión hiperspectral incluyen fuentes de luz, dispositivos de dispersión de longitud de onda y detectores de área (Qin, 2010). En la Figura 39, se presenta un sistema de imagen hiperspectral.



**Figura 39.** Componentes principales de un sistema de imagen hiperspectral de barrido.  
Fuente: ElMasry & Sun, 2010.

#### 2.2.2.1 Fuentes de luz

Uno de los detalles más importantes en la configuración del sistema hiperspectral es la selección de las fuentes de luz y su disposición. Las fuentes de luz comunes en los sistemas de adquisición de imágenes hiperspectrales incluyen lámparas halógenas, diodos emisores de luz-LED y láseres (Qin, 2010).

#### 2.2.2.2 Dispositivos de dispersión

En sistemas de formación de imágenes hiperspectrales, se pueden utilizar diversos instrumentos ópticos y electro-ópticos como dispositivos de dispersión de longitud de onda para dispersar, en bandas, las diferentes longitudes de onda que componen la luz provista por el sistema de iluminación. Dentro de éstos tenemos los espectrógrafos de imágenes, ruedas de filtro, filtros sintonizables acústico-ópticos AOTF (“Acoustic-Optic Tunable Filters”), filtros sintonizables de cristal líquido LCTF (“Liquid Crystal Tunable Filter”), espectrómetros de imágenes por Transformada de Fourier, y cámaras de un solo disparo. (Qin, 2010).

### ***2.2.2.3 Detectores en Sistemas de Imagen Hiperespectral***

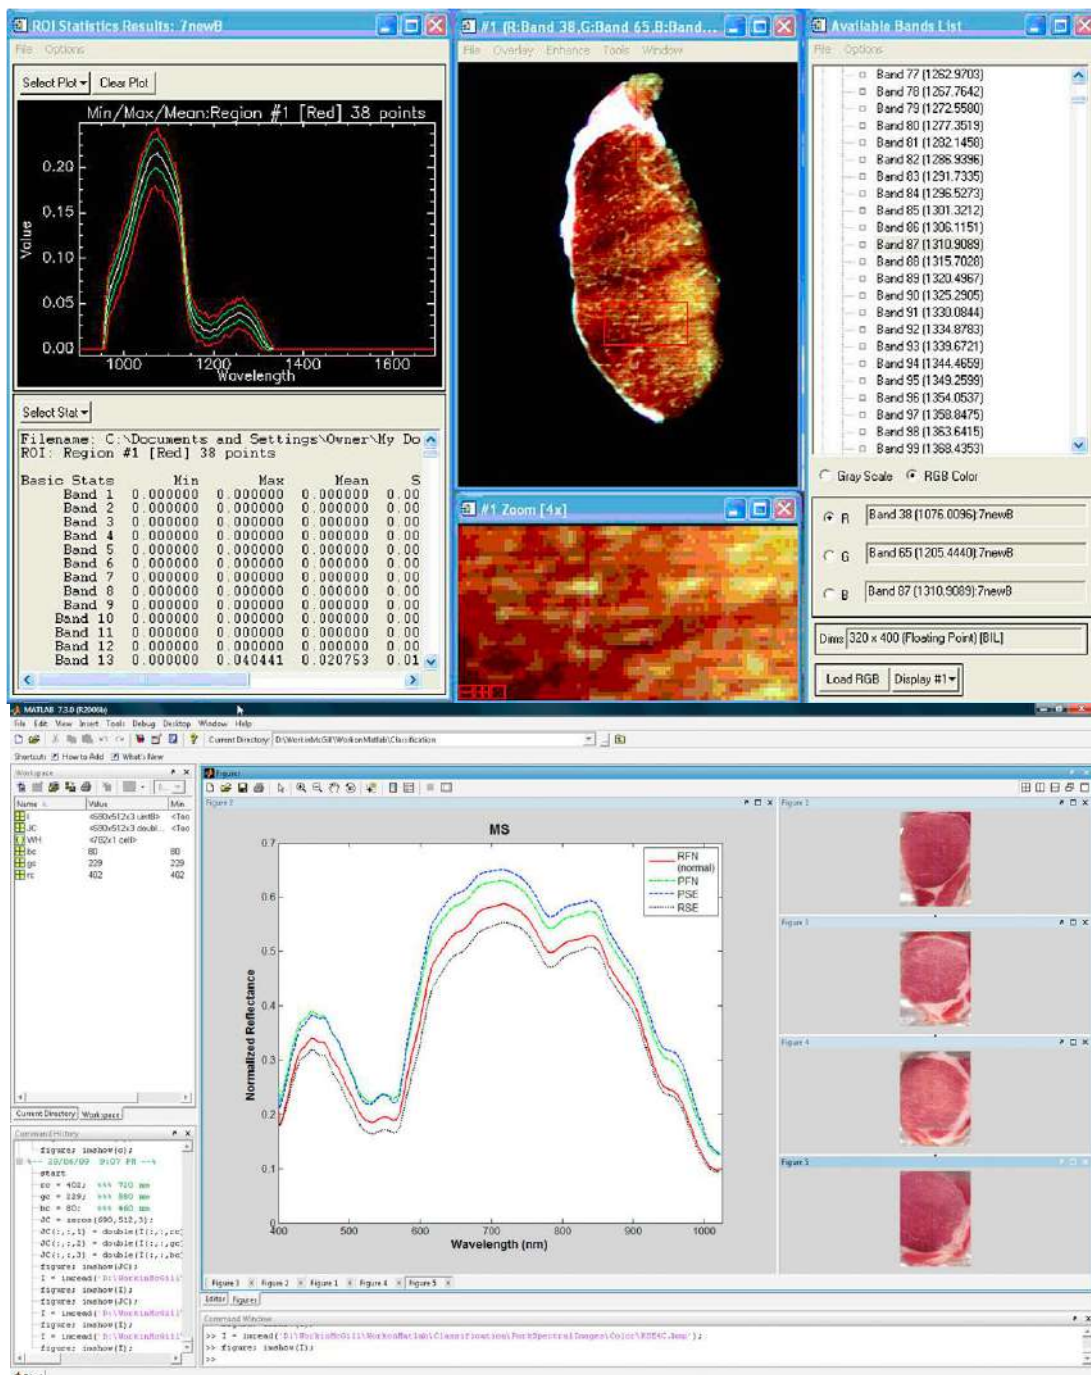
La función del detector es cuantificar la intensidad de la luz recogida convirtiendo la energía de radiación en señales eléctricas a través de un circuito integrado. Existen dos tipos principales de detectores de área de estado sólido que son dispositivo de carga acoplada (CCD) y semiconductor complementario de óxido metálico (CMOS) (Qin, 2010). Se puede utilizar varios elementos detectores superpuestos para optimizar la sensibilidad en diferentes regiones de longitud de onda (ElMasry & Sun, 2010).

### ***2.2.2.4 Software***

Es necesario implementar herramientas de software para controlar las etapas de adquisición, procesamiento y análisis de imágenes hiperespectrales. Una de las herramientas de software más populares es el software “Environment for Visualizing Images” (ENVI) (Research Systems Inc., Boulder, CO, EUA) que es ampliamente utilizado en ingeniería de alimentos, y permite el uso de bibliotecas espectrales de referencia y analizar imágenes de alta resolución espectral de sensores diferentes (Ngadi & Liu, 2010).

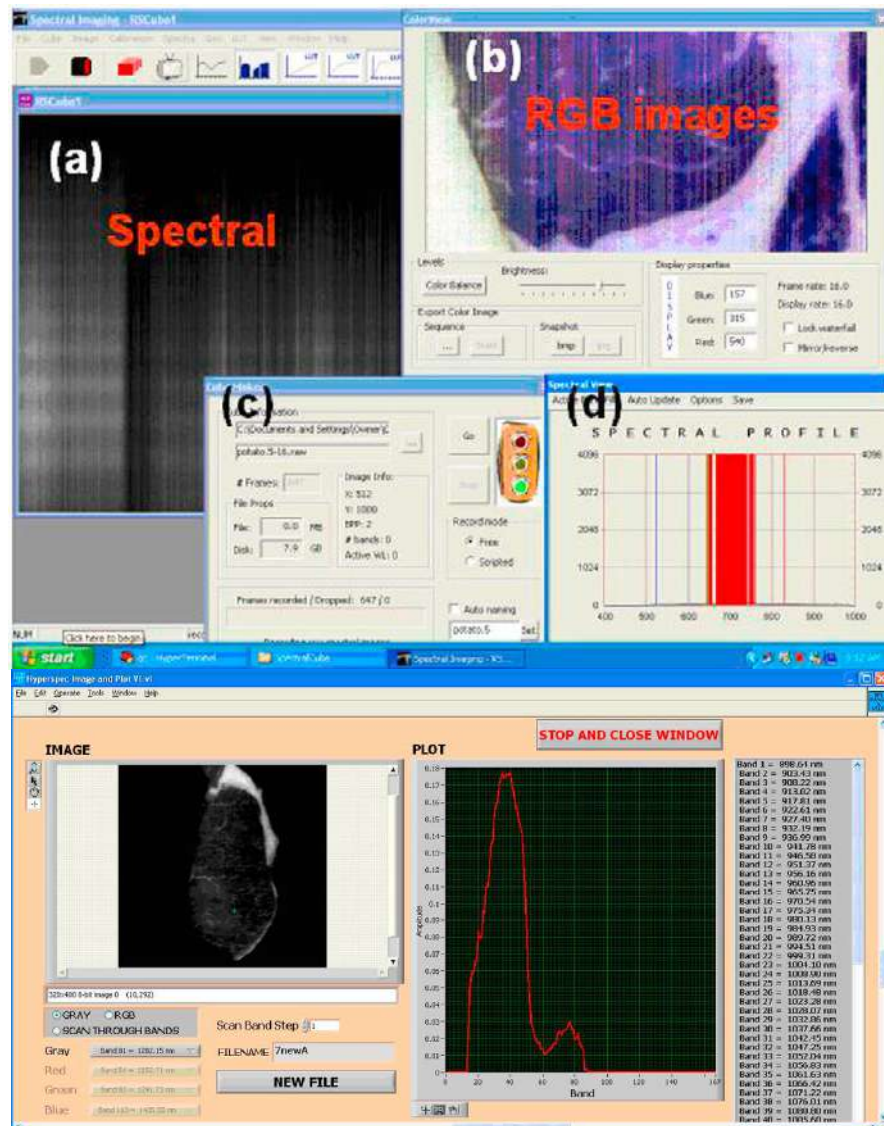
MATLAB (Math-Works Inc., Natick, MA, EE.UU.) es otra herramienta de software ampliamente utilizada, es un sistema de alto rendimiento para la computación técnica, las aplicaciones típicas incluyen las siguientes: cálculos matemáticos, desarrollo de algoritmos, representación de funciones, adquisición y análisis de datos, modelado y simulación de prototipos, gráficos científicos y de ingeniería, creación de interfaces gráficas de usuario (GUI), comunicación con programas en otros lenguajes como C, C++, Java, Fortran y Python, etc. Esto hace que sea cada vez más popular en la ingeniería de alimentos. La interfaz gráfica del software ENVI y MATLAB se muestran en la Figura 40.

Existen otras herramientas de software como “SpectraCube” (Auto Visión Inc., CA, EE.UU.) y “Hyperspec” (Headwall Photonics, Inc., MA, USA) (Ngadi & Liu, 2010). La interfaz gráfica del software “SpectraCube” e “Hyperspec” se muestran en la Figura 41.



**Figura 40.** Interfaz gráfica del software ENVI y MATLAB.  
Fuente: Ngadi & Liu, 2010.



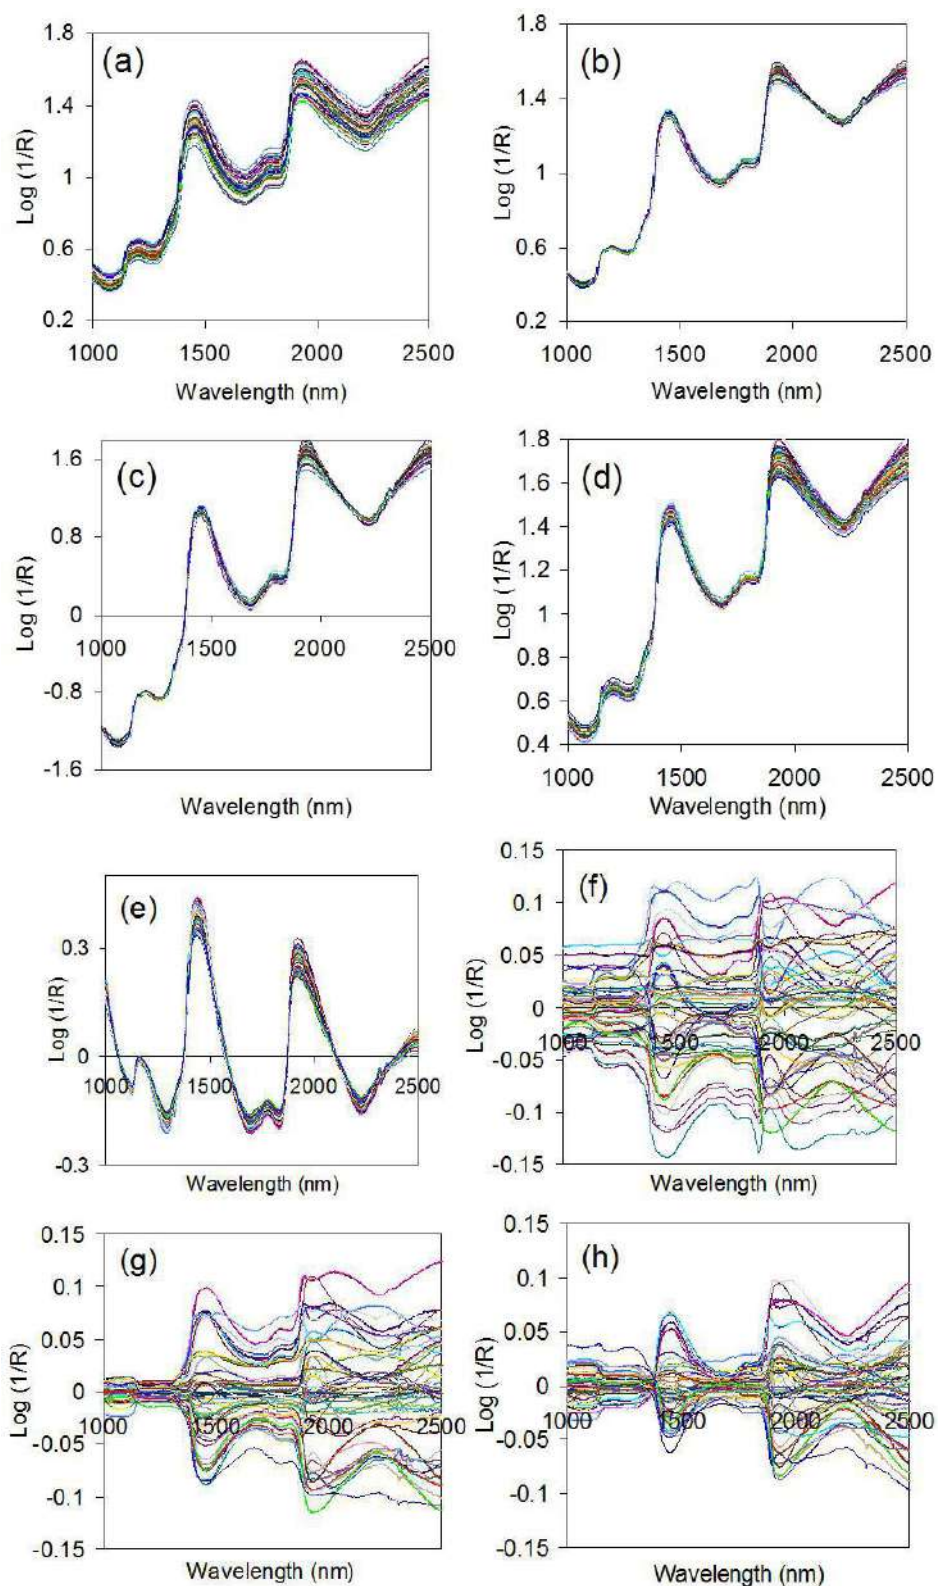


**Figura 41.** Interfaz gráfica del software “SpectraCube” y “Hyperspec”.  
Fuente: Ngadi & Liu, 2010.

### 2.3 Análisis de imagen hiperespectral

Los datos espectrales que se extraen de la imagen hiperespectral de la muestra deben ser procesados para reducir el ruido y mejorar la resolución. El preprocesamiento incluye operaciones espectrales (filtros espectrales, normalización, centrado medio, escalado automático, corrección de línea base, diferenciación, variación normal estándar, corrección de dispersión multiplicativa y suavizado) y espaciales (filtros de paso bajo, filtros de paso alto). Después del preprocesado, se analiza cualitativamente los componentes de la muestra. Para ello se usan herramientas de quimiometría. También se realiza un análisis cuantitativo para determinar las concentraciones estimadas de los componentes y su distribución espacial (ElMasry & Sun, 2010). En la Figura 42, se presentan algunas técnicas de preprocesamiento.





**Figura 42.** Espectro en bruto (a), espectro de Corrección Multiplicativa de Dispersión (MSC) (b), espectro Estándar de Variación Normal (SNV) (c), espectro de Normalización Media (MN) (d), espectro de Desviación (DT) (e), espectro de Centrado Medio (MC) (f), espectro de Corrección de Señal Ortogonal (OSC) de acidez valorable (g), espectro OSC de contenido de sólidos solubles (h).

Fuente: Munawar, 2014.

Varias longitudes de onda esenciales se podían clasificar a través de distintas técnicas como inspección visual de las curvas espectrales y coeficientes de correlación, análisis de las diferencias espectrales del espectro promedio, la regresión por etapas, el análisis discriminante, el análisis de componentes principales (PCA), mínimos cuadrados parciales (PLS), Análisis Discriminante de Fisher (FDA), Análisis Discriminante Lineal (LDA) y otros (Tao, 2011).

Para la prueba de validación de los modelos obtenidos de las etapas anteriores, se pueden utilizar varios procedimientos, como la validación cruzada “leave-one-out” que consiste en usar todos los datos excepto uno y se realiza una predicción con estos datos, se repite la operación para cada grupo de datos y con los resultados se evalúa el modelo. También existe la validación cruzada interna, donde los datos se dividen en dos subconjuntos, uno para la calibración con dos tercios de las muestras y un tercio para la validación. Finalmente la validación externa realiza la evaluación del modelo establecido con muestras independientes (Bureau, 2009).

### **2.3.1 Pretratamiento espectral y calibración**

La necesidad de preprocesamiento espectral y calibración de datos se debe a los defectos sistemáticos de los componentes ópticos y electrónicos del sistema hiperespectral. Además, se introducen errores y ruido en el proceso de adquisición de imágenes. Cinco técnicas para la reducción de ruido son las más comunes: resta de corriente oscura, filtrado espectral de paso bajo, filtrado de Savitzky-Golay, eliminación de banda ruidosa y transformación mínima de fracción de ruido (Yao & Lewis, 2010).

Según (ElMasry & Sun, 2010), el procedimiento de calibración se realiza después de ensamblar todos los componentes del sistema de imágenes hiperespectral. La primera precaución en el proceso de calibración es verificar la temperatura de funcionamiento inicial del sistema. Además, la combinación de la intensidad de la lámpara y el tiempo de integración del detector debe ajustarse para evitar la saturación del convertidor analógico a digital (A/D). A continuación, el paso más importante es la calibración de la banda de ondas espectrales (calibración de la longitud de onda) que identifica cada canal espectral con una longitud de onda específica. Para determinar la relación entre la distancia (en píxeles) en el eje espectral y la longitud de onda, el eje espectral debe calibrarse utilizando una lámpara de emisión estándar como fuente de luz.

Finalmente, después de adquirir imágenes hiperespectrales, se debe realizar la calibración de reflectancia, para tener en cuenta la respuesta espectral de fondo del instrumento y la corriente "oscura" de la cámara. El fondo se obtiene mediante la adquisición de una imagen espectral a partir de un estándar uniforme de alta reflectancia o cerámica blanca (~ 100% de reflectancia), y la respuesta oscura (~ 0% de reflectancia) se adquiere registrando una imagen cuando se apaga la fuente de luz y la lente de la cámara está completamente cubierta con su tapa negra opaca no reflectante.

Estas dos imágenes de referencia se utilizan entonces para calcular la reflectancia relativa basada en píxeles para las imágenes de exploración lineal en bruto usando la siguiente fórmula:

$$I = \frac{I_0 - D}{W - D}$$

Donde I es la imagen de reflectancia relativa,  $I_0$  es la imagen de reflectancia cruda, D es la imagen de referencia oscura y W es la imagen de referencia blanca.

La imagen hiperespectral corregida también puede expresarse en absorbancia (A) tomando los logaritmos de la ecuación anterior como:

$$A = -\log_{10} \left( \frac{I_0 - D}{W - D} \right)$$


### 2.3.2 Clasificación

A continuación se presentan los enfoques principales de los métodos de extracción de características y reconocimiento de patrones (Jiang et al., 2010).


#### 2.3.2.1 Característica óptima y extracción de banda

Este enfoque tiene dos pasos esenciales, que son la extracción de características y la clasificación de patrones. El paso de extracción de características también se denomina selección o extracción óptima de bandas, cuyo objetivo es reducir o transformar el espacio de características en otro espacio representativo de las características originales con menor dimensión. La técnica más popular es el Análisis de Componentes Principales (PCA) (ver Figura 43) seguido de agrupación “K-means” (ver Figura 44). El agrupamiento “K-means” clasifica las muestras en k núcleos en los que cada muestra pertenece al núcleo con el que tiene la menor distancia al centroide del núcleo (Wu & Sun, 2013).

Existen otras técnicas como el Análisis Discriminante de Fisher (FDA), Análisis Independiente de Componentes (ICA), Mínimos Cuadrados Parciales (PLS), Análisis Discriminante Lineal (LDA), entre otros (Jiang et al., 2010).



**Figura 43.** Tres principales componentes principales (PC) para muestras de granos de cacao según su origen geográfico.  
Fuente: Teye et al., 2013.



**Figura 44.** KNN donde cada característica se considera como un eje de coordenadas y la distancia entre los puntos en este espacio determina cuán similares o diferentes son.  
Fuente: García-Allende et al., 2011.

### a) Selección de funciones Métrica

El objetivo es optimizar un equilibrio entre la precisión de clasificación y la velocidad computacional. El criterio de selección de características evalúa la discriminación de un subconjunto de características de acuerdo con una métrica de distancia estadística. La métrica de distancia más simple y popular es la distancia euclídea. Otras métricas de distancia que se han utilizado en la selección de características son la métrica basada en la norma  $L_1$  o también llamada distancia de Manhattan, y la métrica basada en norma  $L_p$ . Algunas más complejas incluyen la distancia de Bhattacharyya, distancia de Jefferies-Matusita (JM) y la medida de divergencia (Jiang et al., 2010).

### b) Estrategia de búsqueda de funciones

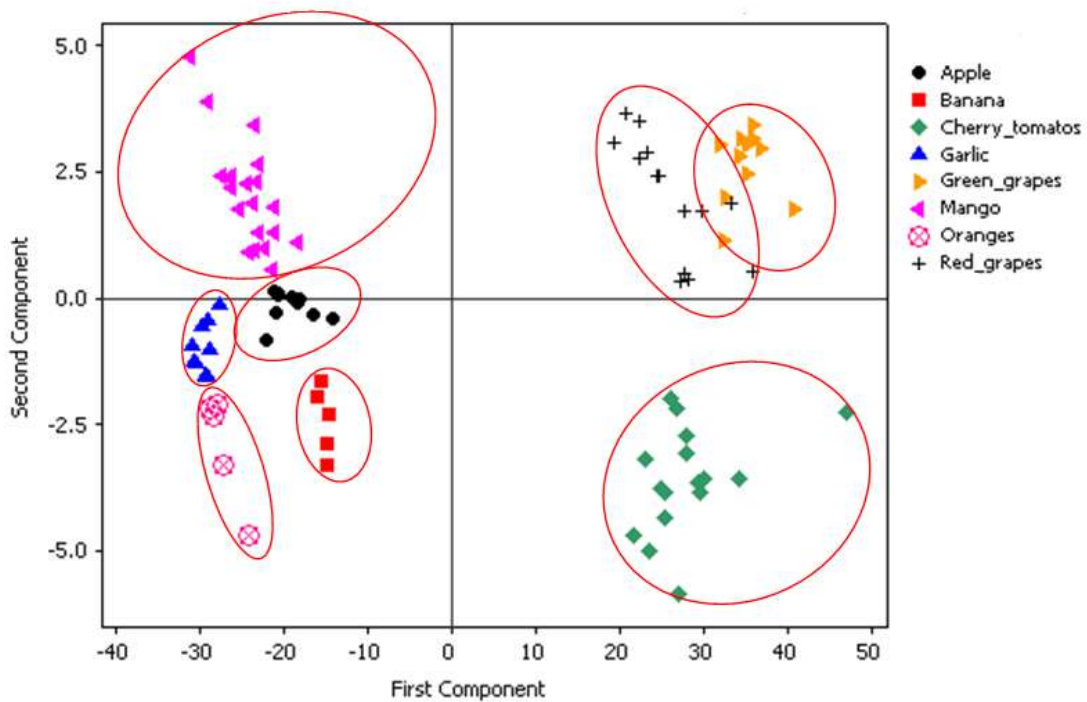
Los algoritmos óptimos de búsqueda de funciones identifican un subconjunto que contiene un número predeterminado de características y es el mejor en términos de la función de criterio adoptada. Las técnicas más sencillas de realizar la búsqueda de funciones son las selecciones secuenciales hacia adelante y hacia atrás. El método de selección secuencial hacia adelante (SFS) comienza sin características y las agrega uno por uno, añadiendo en cada paso la que más disminuye el error, hasta que cualquier adición adicional no disminuya significativamente el error. El método de selección secuencial hacia atrás (SBS) comienza con todas las características y las elimina una por una, eliminando en cada paso la que más disminuye el error de clasificación (o lo aumenta sólo ligeramente) hasta que cualquier eliminación adicional no aumente significativamente el error. La desventaja de estas selecciones es que cuando se elimina una característica en SBS, no se puede volver a capturar en la siguiente selección y cuando se agrega una característica en SFS, no se puede eliminar (Jiang et al., 2010).

El método secuencial de selección flotante hacia adelante (SFFS) y el método de selección flotante hacia atrás secuencial (SBFS) mejoran las técnicas estándar de SFS y SBS, respectivamente, cambiando el número de características incluidas (SFFS) o eliminadas (SBFS) en cada paso y permitiendo la reconsideración de las características incluidas o eliminadas en los pasos anteriores (García-Allende et al., 2011).

### c) Análisis de Componentes Principales (PCA)

El método PCA es un método de aprendizaje sin supervisión y se utiliza a menudo para la selección de características, reducción de la dimensión de datos y resolver la multicolinealidad. Este método transforma una matriz de datos de variables correlacionadas entre sí en un nuevo conjunto de variables ortogonales conocidas como Componentes Principales (PCs) (o variables latentes, LVs). Los PCs están ordenados de tal manera que el primer PC corresponde a la mayor varianza, el segundo componente corresponde a la segunda mayor varianza y así sucesivamente (Lorente et al., 2012; Travers, 2013).

El rendimiento del clasificador mejora a medida que los componentes principales aumentan hasta cierto punto; pero el tiempo de cálculo también aumenta. Debe equilibrarse el rendimiento del clasificador y el tiempo de cálculo (Jiang et al., 2010). En la Figura 45, se muestra un ejemplo de análisis de componentes principales.



**Figura 45.** Análisis de componentes principales de algunos productos agrícolas basados en espectros de reflectancia difusa de reflectancia del infrarrojo cercano.

Fuente: Munawar, 2014.

#### d) Análisis discriminante

El análisis discriminante es una técnica estadística que identifica las características que discriminan entre dos o más clases y a crear una función que separe con la mayor precisión posible a los miembros de cada grupo. El análisis discriminante lineal (LDA) es método de aprendizaje supervisado que maximizar la relación de la varianza entre los grupos y la varianza dentro de los grupos (Lorente et al., 2012).


El análisis discriminante de Fisher (FDA) es un método de aprendizaje supervisado que selecciona una proyección de tal forma que se maximiza la relación de la dispersión entre clases y la dispersión dentro de cada clase. El análisis de componentes independientes (ICA) extrae señales de fuente independientes buscando una transformación lineal o no lineal que minimice la dependencia estadística entre componentes (Jiang et al., 2010).

#### 2.3.2.2 Clasificación basada en las estadísticas de 1er y 2do orden

Este enfoque utiliza el modelo de densidad de probabilidad normal multivariado (Gaussiano), que requiere la estimación correcta de las estadísticas de primer y segundo orden para cada categoría. El modelo mixto Gaussiano (GMM) es un método clásico en esta categoría y ha sido utilizado en muchas aplicaciones de modelado de datos, tales como la clasificación en series temporales y la detección de la textura de imágenes (Jiang et al., 2010).

### 2.3.2.3 Clasificación basada en redes neuronales

Las redes neuronales es un método de clasificación de uso común debido a su propiedad no lineal y el hecho de que no necesita hacer suposiciones sobre la distribución de los datos. Simulan el comportamiento de las redes neuronales biológicas para el aprendizaje y la predicción. Una red neuronal multicapa típica incluye capa de entrada, capa oculta y capa de salida. Cada entrada está conectada con células llamadas neuronas. Cada neurona de la capa de entrada está conectada a cada neurona de la capa oculta, y cada neurona de la capa oculta está conectada a la capa de salida. Los nodos en cada capa tienen diferentes funciones y pesos en las redes neuronales. La red neuronal más popular es el perceptrón multicapa (MLP) que emplea una gran variedad de técnicas de aprendizaje, siendo la más común la de retropropagación (Lorente et al., 2012). Un ejemplo de red neuronal artificial se muestra en la Figura 46.



**Figura 46.** Una red neuronal artificial de avance múltiple.  
Fuente: Jiang et al., 2010.

### 2.3.2.4 Método de kernel o núcleo

Este enfoque está diseñado para abordar las características específicas de las imágenes hiperespectrales, que son el alto número de canales espectrales y relativamente pocas muestras de entrenamiento etiquetados. Un popular método basado en kernel es la máquina de vector de soporte (SVM) (Munawar, 2014).



## **2.4 Ventajas y desventajas**

### **2.4.1 Ventajas de la imagen hiperespectral**

Las principales ventajas del uso de la tecnología de imágenes hiperespectrales en el análisis de los alimentos pueden resumirse en los siguientes puntos (ElMasry & Sun, 2010):

- No se requiere preparación de la muestra o preparación mínima.
- Es un método de evaluación libre de químicos, y por lo tanto permite la protección del medio ambiente.
- Es un método no invasivo y no destructivo.
- Es económico en comparación con los métodos tradicionales de inspección.
- Tiene la flexibilidad de elegir cualquier región de interés (ROI) en la imagen incluso después de la adquisición de la imagen.
- Debido a su alta resolución espectral, la imagen hiperespectral proporciona tanto medidas cualitativas como cuantitativas.
- Permite la visualización de diferentes constituyentes bioquímicos por medio de sus firmas espectrales.
- La mayor información espectral en las imágenes espectrales permite detectar y distinguir muchos objetos diferentes, incluso si tienen colores similares, características morfológicas o espectros superpuestos.
- Mediante el análisis de los datos de imágenes hiperespectrales, es posible seleccionar unas pocas bandas de ondas adecuadas para construir un sistema de imágenes multiespectral y así cumplir con el requerimiento de una mayor velocidad en las líneas de producción.

### **2.4.2 Desventajas y limitaciones de la imagen hiperespectral**

La formación de imágenes hiperespectrales presenta algunas desventajas, que pueden resumirse como sigue (ElMasry & Sun, 2010; Lorente et al., 2012):

- Las imágenes hiperespectrales contienen una gran cantidad de datos, incluyendo mucha información redundante, por lo que su análisis representa un trabajo computacional considerable. Esto dificulta la implementación de los sistemas de imágenes hiperespectrales en la inspección en línea de productos alimenticios, agrícolas e industriales.
- La adquisición, procesamiento y el análisis de imágenes tardan mucho tiempo.
- Uno de las principales limitaciones analíticas de la visión hiperespectral es que se trata de un método indirecto, es decir, necesita calibración y procedimientos de transferencia de modelos.
- Los datos espectrales extraídos de la imagen contienen una serie de bandas sucesivas que se superponen, que son difíciles de asignar a grupos químicos específicos.
- Uno de los principales problemas de los datos hiperespectrales es la multicolinealidad, que ocurre cuando diferentes variables se correlacionan dentro de un conjunto de datos específicos.




- La imagen hiperespectral no es apropiada de aplicarse en algunos casos, como líquidos o muestras homogéneas, porque el valor de la imagen radica en la capacidad de resolver heterogeneidades espaciales en las muestras.
- Dependiendo de la resolución espacial y de la estructura de la muestra investigada, los píxeles de una imagen pueden no representar un espectro puro de un material singular, sino un espectro mixto que consiste en respuestas espectrales de los diversos materiales que cubren la región de interés.
- Otras limitaciones que se presentan son el alto costo de compra de los sistemas hiperespectrales.
- El software y algoritmos comerciales de imágenes hiperespectrales, tales como ENVI, son desarrollados para fines de teledetección y no son adecuados para realizar inspecciones en línea de calidad de productos agrícolas.

## 2.5 Aplicaciones

La visión hiperespectral comenzó a principios de los años setenta con aplicaciones en la teledetección principalmente (Goetz et al., 1985). Actualmente, la técnica de imágenes hiperespectrales se ha implementado en varias aplicaciones, como en ciencias forenses (Silva et al., 2014), bioquímica y medicina (Lu & Fei, 2014), minería (Choe et al., 2008), e industria alimenticia (Lorente et al., 2012; Wu & Sun, 2013).

En especial, varios artículos de investigación sobre la aplicación de imágenes hiperespectrales en la evaluación de la calidad de productos agrícolas se han publicado en los últimos años. Entre algunas aplicaciones se encuentran la determinación del contenido de sólidos solubles y firmeza (Infante et al., 2011), evaluación de acidez (Fernandes et al., 2015), detección de daños o infecciones (Gómez, 2010), determinación del contenido de azúcar (Lorente et al., 2012), evaluación del estado de madurez (Lleó et al., 2011), y determinación del contenido de pigmentos (Fernandes et al., 2015). En la Figura 47, se observa un ejemplo de aplicación de sistemas hiperespectrales.



**Figura 47.** Defectos comunes en cítricos: rameados (a), pérdida de pedúnculo (b), punción por pedúnculo (c), fitotoxidad (d), trips (e), serpetas (f), negrilla (g), daño por frío (h), oleocelosis (i), *Penicillium digitatum* (j), antracnosis (k), y picadura de mosca (l).

Fuente: Gómez, 2010.



## Capítulo 3

### Materiales y métodos

#### 3.1 Sistema de imágenes hiperespectrales


El sistema de adquisición y análisis de imágenes hiperespectrales es un elemento esencial en el desarrollo de las labores de investigación pues debe asegurar la obtención de imágenes de calidad, reduciendo así el tiempo y necesidad de preprocesamiento a aplicar sobre las imágenes obtenidas.

El sistema de imágenes hiperespectrales utilizado Resonon, es un sistema integral de hardware y software para la adquisición y análisis de datos hiperespectrales (ver Figura 48). El sistema de adquisición de imágenes hiperespectrales fue de modo de reflectancia en un rango espectral visible e infrarrojo cercano de 400 - 900 nm, mostrado en la Figura 49, con escaneo en línea (“Pushbroom”).



**Figura 48.** Sistema Resonon usado para el análisis de los parámetros internos de los granos de cacao.

Fuente: Elaboración propia.




**Figura 49.** Rango Hiperspectral de la Cámara Pika II.  
Fuente: Resonon.

El sistema consiste de: (a) cámara de imágenes hiperspectrales VNIR (Pika IIg, Resonon Inc., EE.UU) con cámara CMOS y lentes objetivo; (b) montaje de iluminación con 4 lámparas halógenas de cuarzo; (c) fuente de alimentación; (d) plataforma de desplazamiento de muestra con motor; (e) torre de montaje de aluminio acanalada; (f) plataforma de teflón blanco; (g) laptop con sistema operativo Windows 7 con un software SpectrononPro de adquisición y procesamiento de datos. En la Figura 50, se muestran los accesorios del sistema de imágenes hiperspectrales.



**Figura 50.** Accesorios de imágenes hiperspectrales.  
Fuente: Resonon.

El Pika II es un instrumento de fácil manejo, compacto y robusto, cuenta con una excelente calidad de imagen, alta Relación de Señal y Ruido (SNR), bajas distorsiones y poca luz parásita. La lente del objetivo determina el campo de visión de la imagen (FOV) y el campo de visión instantáneo (IFOV) (ver Figura 51).



**Figura 51. IFOV.**

Fuente: Resonon.

Las características técnicas de la cámara se muestran en la Tabla 4:

**Tabla 4.** Especificaciones de la cámara Pika II.

Especificaciones de la cámara Pika II	
Spectral Range	400-900 nm
Spectral Resolution	2.1 nm
Spectral Channels*	240
Spatial Channels	640
Max Frame Rate	145 fps
Bit Depth	12
Connection Options	GigE
Power Requirements	8-30 V, < 2.5 W
Weight	2.8 lbs, 1.3 kg
Dimensions (in)	3.8 x 6.6 x 2.5
Dimensions (cm)	9.7 x 16.8 x 6.4
Temperature range	46-90 F, 8-32 C
f / #	f / .0
Avg. RMS Spot Radius	7 um
Smile (peak to peak)	5 um
Keystone (peak to peak)	7 um
Pixel size	7.4 um

Fuente: Datasheet de Pika II Resonon.

### 3.1.1 Calibración del sistema Resonon

La calibración del sistema es un proceso que siempre se debe realizar para disminuir el efecto de la iluminación no homogénea, en nuestro caso se realizó mediante una función automática en el software de adquisición de imágenes SpectrononPro. A continuación se presentan los pasos definidos en la guía de la cámara Resonon.

#### a) Enfocar lente de cámara

Primero se enfoca el lente objetivo del espectrómetro. Se hace click en el botón de Enfoque (F) ubicado en la barra de herramientas de SpectrononPro, mostrada en la Figura 52, y a continuación aparece una imagen en vivo desde la cámara.



**Figura 52.** Barra de herramientas en SpectrononPro.

Fuente: Datasheet de SpectrononPro.

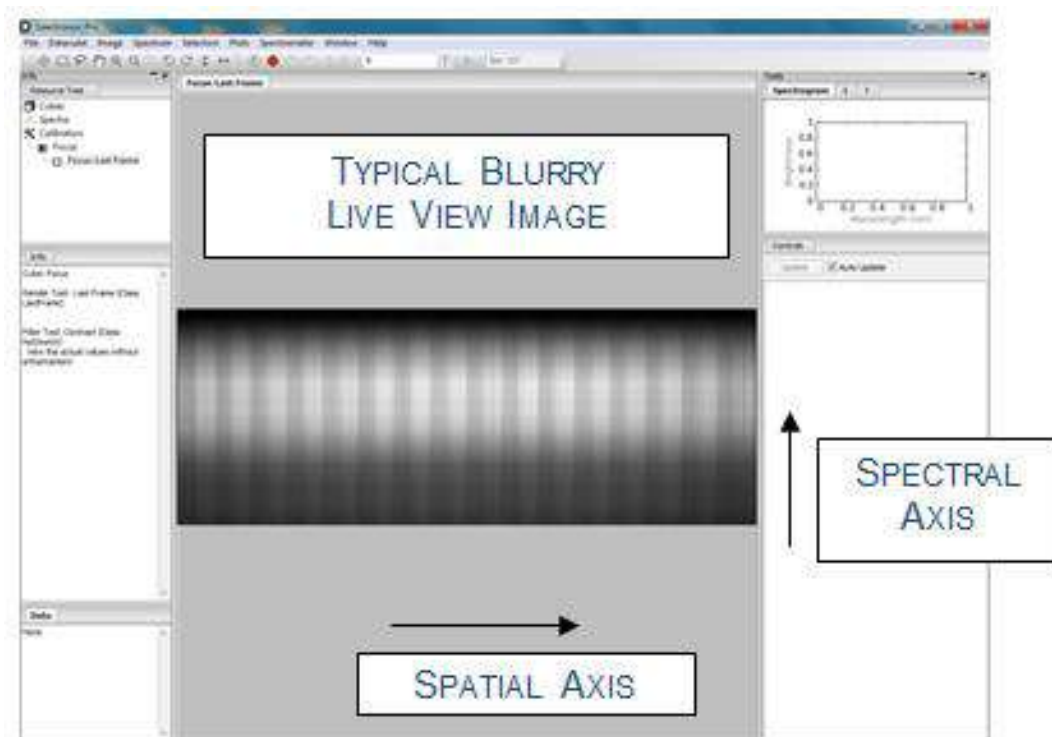
Se utiliza una hoja de papel con líneas oscuras, como la que se observa en la Figura 53, si el lente no está enfocado se verán unas líneas borrosas (ver Figura 54).

### Focusing Sheet



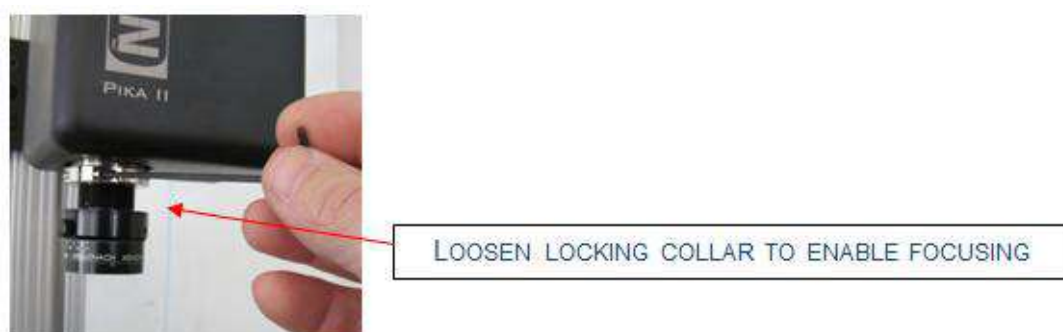
**Figura 53.** Plantillas para calibrar el lente.

Fuente: Datasheet de SpectrononPro.



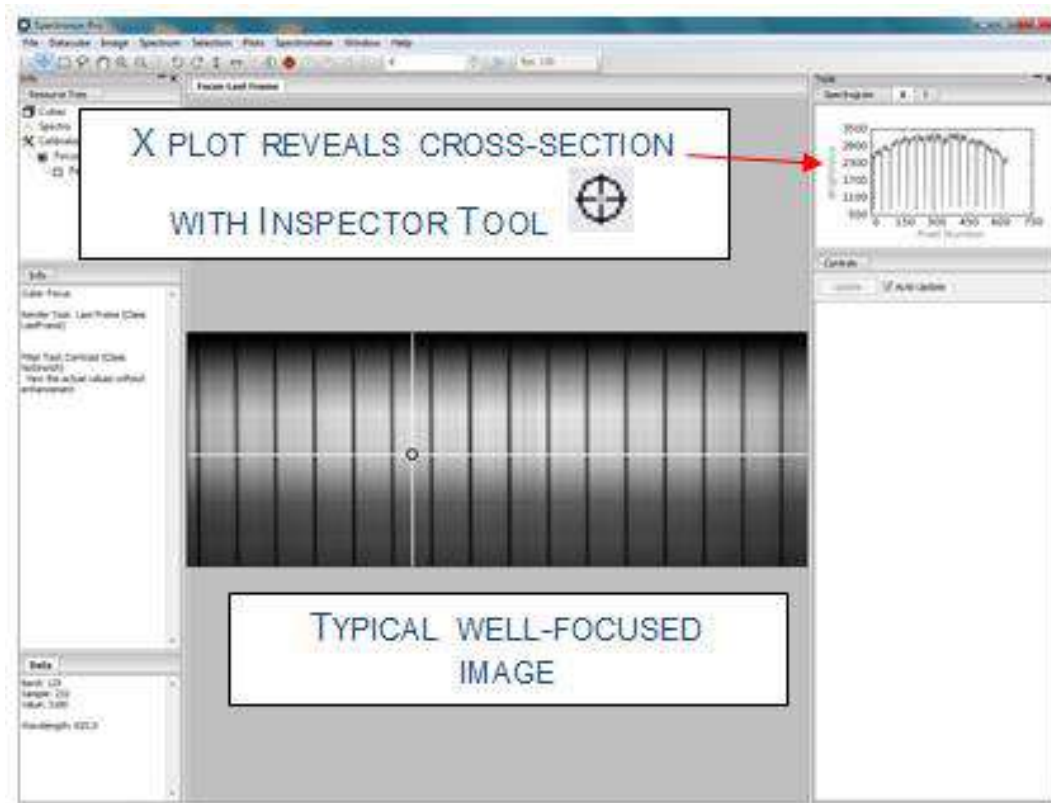
**Figura 54.** Lente no enfocado.  
Fuente: Datasheet de SpectrononPro.

Para ajustar el enfoque, primero se desbloquea el ajuste de enfoque. Con las lentes Schneider, esto se logra aflojando el collar de metal de bloqueo en la lente de su objetivo con una llave Allen de tamaño 5/64 pulgadas, como se observa en la Figura 55.



**Figura 55.** Afloje de collar con llave Allen.  
Fuente: Datasheet de SpectrononPro.

Luego rotamos el lente objetivo hasta lograr ver líneas gruesas y bien definidas, como se observa en la Figura 56.



**Figura 56.** Lente enfocado.  
Fuente: Datasheet de SpectrononPro.

b) Remover la corriente oscura

La corriente oscura es la corriente eléctrica residual que fluye en un dispositivo fotoeléctrico cuando no hay iluminación incidente. Primero se hace click en el botón Dark Current (D) en la barra de herramientas SpectrononPro, luego el programa indica que se bloquee la lente objetivo con una tapa negra (ver Figura 57). El botón Dark Current aparecerá con una marca roja al terminar de remover la corriente oscura y se procede a retirar la tapa negra del lente objetivo.



**Figura 57.** Ventana de aceptación SpectrononPro.  
Fuente: Datasheet de SpectrononPro.



c) Definir la reflectancia de referencia

La medición de la reflectancia absoluta de un objeto requiere que se tenga en cuenta los efectos de iluminación. Para hacer esto, haga clic en el botón Cubo de corrección de respuesta (R) en la barra de herramientas de SpectrononPro. El material de referencia es una lámina de teflón blanco.

Una vez colocado el material de referencia se procede a la captura del material y una vez terminado el escaneo, botón R aparecerá con una marca de verificación roja, lo que indica que los datos recogidos se escalarán según el material de referencia (ver Figura 58).



**Figura 58.** Verificación.

Fuente: Datasheet de SpectrononPro.

Cuando el generador de imágenes está calibrado para la corriente oscura y referencia de reflectancia, este permanecerá calibrado hasta que se eliminen las referencias o la máquina se apague. Si se cambia el tiempo de integración después de la calibración, las señales de referencia se ajustarán. Para eliminar las referencias manualmente se elige Spectrometer→Remove Dark Current Cube, y Spectrometer→Remove Response Correction Cube.

d) Ajustar la relación de aspecto

Para escanear una imagen, se ingresa el número de líneas a escanear en la ventana ubicada a la izquierda del botón Escanear (ver Figura 59). Un número como 200 a menudo es bueno inicialmente. Una vez escaneada la imagen se puede utilizar las herramientas de visualización y análisis de SpectrononPro.




**Figura 59.** Barra de Herramientas.

Fuente: Datasheet de SpectrononPro.

La primera imagen puede aparecer distorsionada en una dimensión. Para corregir esta distorsión, se debe ajustar el tamaño de paso del sistema de escaneo, es decir, se debe ajustar el espaciado de las líneas utilizadas para construir la imagen.

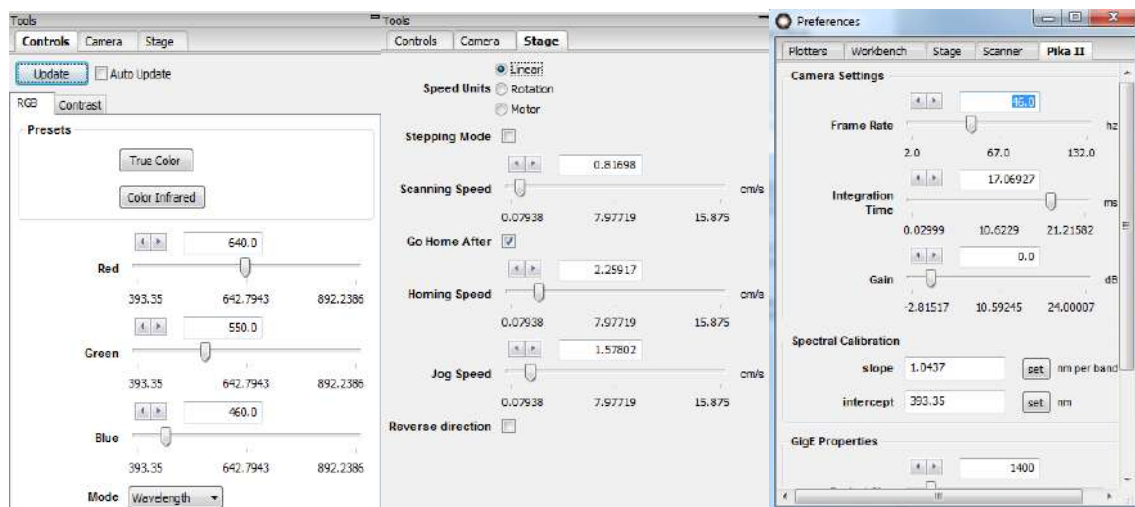
Para ajustar la relación de aspecto de la imagen, es útil visualizar un objeto cuya distorsión es fácil de observar, como un círculo. Se utiliza una hoja de calibración de relación de aspecto, donde se observa una serie de círculos superpuestos, y se graba un escaneo con suficientes líneas para que pueda ver el círculo completo, como se observa en la Figura 60. Si la imagen está distorsionada a lo largo de la dirección de escaneo, se cambia la velocidad de escaneo en la pestaña “Stage” en el panel de herramientas.

Después de restablecer los pasos por escaneo, se graba una nueva imagen para observar el cambio en la distorsión de la imagen.



**Figura 60.** Plantillas para calibrar el lente.  
Fuente: Datasheet de SpectronPro.

Los parámetros finales de la calibración en este experimento se muestran en la Figura 61.

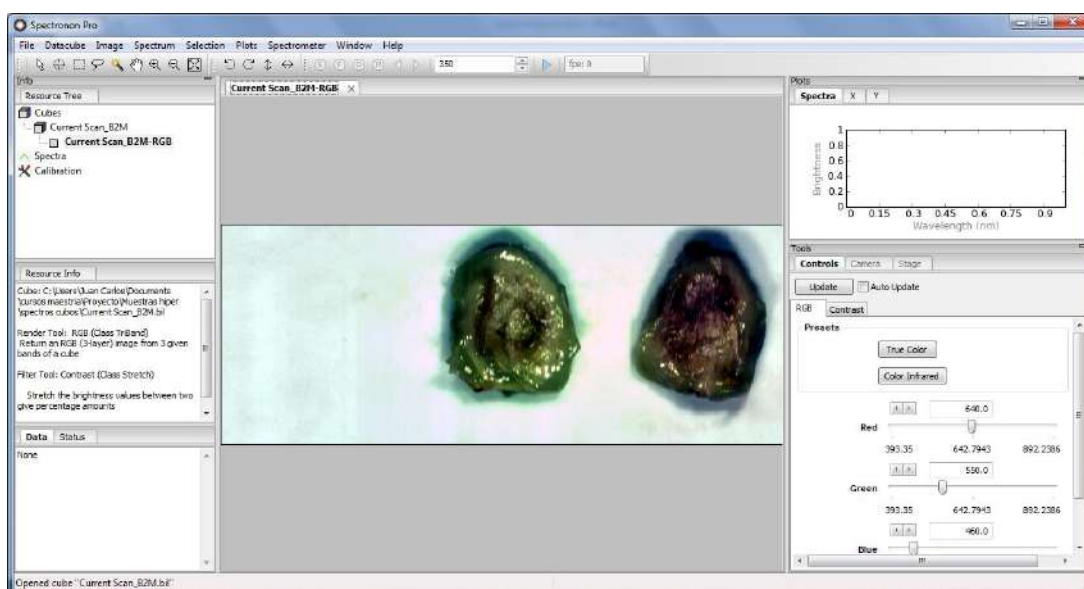


**Figura 61.** Parámetros al finalizar calibración.  
Fuente: Elaboración propia.

### 3.1.2 Software de adquisición de datos

Para la adquisición y procesamiento de imágenes hiperespectrales, se usó el software SpectrononPro, RESONON Inc. - USA. Las cámaras de imagen hiperespectrales de Resonon pueden operarse utilizando el software SpectrononPro, que controla las cámaras y la etapa de escaneo (número de fotogramas, longitudes de onda a muestrear, velocidad de desplazamiento) y tiene muchas herramientas para el procesamiento y análisis de datos hiperespectrales adquiridos por la cámara. SpectrononPro también tiene capacidad para aceptar complementos escritos por el usuario, lo que le permite al usuario integrar algoritmos personalizados de análisis de datos en el software y brindan numerosas opciones de salida para informes y presentaciones. SpectrononPro está disponible como descarga gratuita en el sitio web de Resonon <http://www.resonon.com/> y corre en el sistema operativo Windows.


SpectononPro cuenta con una interfaz (ver Figura 62) que permite visualizar la imagen adquirida en formato RGB y en diferentes longitudes de onda, además permite seleccionar y analizar espectros puntuales y de área.



**Figura 62.** Software SpectrononPro para el análisis hiperespectral.  
Fuente: Elaboración Propia.

Algunas herramientas de análisis de datos son: clasificación hiperespectral (Mapeador de ángulo espectral SAM, regresión logística, etc.), desmezcla de utilidades, índices de vegetación hiperespectral, herramientas de visualización avanzada y plugins escritos por el usuario (lenguaje de programación Python).

El software SpectrononPro de Resonon facilita la creación de mapas HVI (Índices hiperespectrales de vegetación) a partir de datos hiperespectrales que se utilizan en el análisis de plantas o productos agrícolas. En la Figura 63, se muestran algunos índices hiperespectrales en el Software SpectrononPro.



**Figura 63.** Índices hiperespectrales en Software SpectrononPro.

Grano derecho: blanco - Grano izquierdo: morado.

Fuente: Elaboración Propia.

### 3.2 Interfaz gráfica

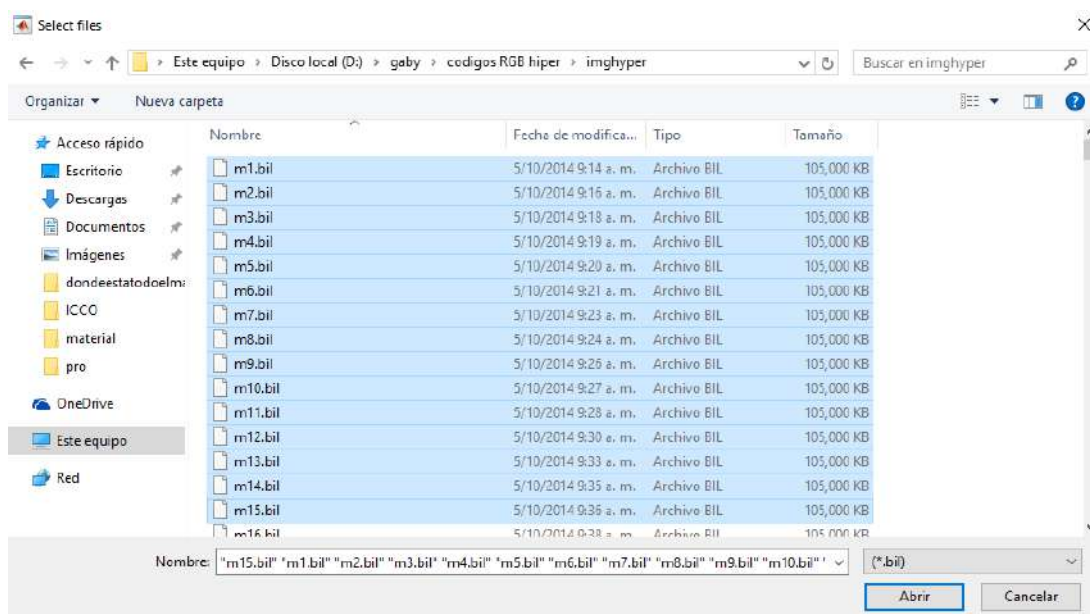
El programa Matlab ha sido utilizado en la implementación de la interfaz del sistema de clasificación.

La Interfaz gráfica del sistema de análisis externo de granos de cacao está conformada por:

- Cuadros de imágenes:  
Una imagen hiperespectral importada.  
Una ventana de procesamiento de imagen hiperespectral.
- Gráfica de firma espectral.
- Tabla de valores: nombre de archivo, índices espectrales y color interno.

La interfaz cuenta además con 3 tipos de botones. La función de los botones es como sigue:

- “Import” (Importar): Este botón permite cargar, desde una base de datos, la imagen hiperespectral de un grano de cacao en la etapa de cosecha. Una vez que se elige la imagen a procesar, ésta se carga en la ventana ubicada en la parte superior de la interfaz. Se pueden importar más de una imagen pero solo la última imagen aparece en la ventana (ver Figura 64).



**Figura 64.** Importar imágenes hiperespectrales para la clasificación según color interno.  
Fuente: Elaboración propia.

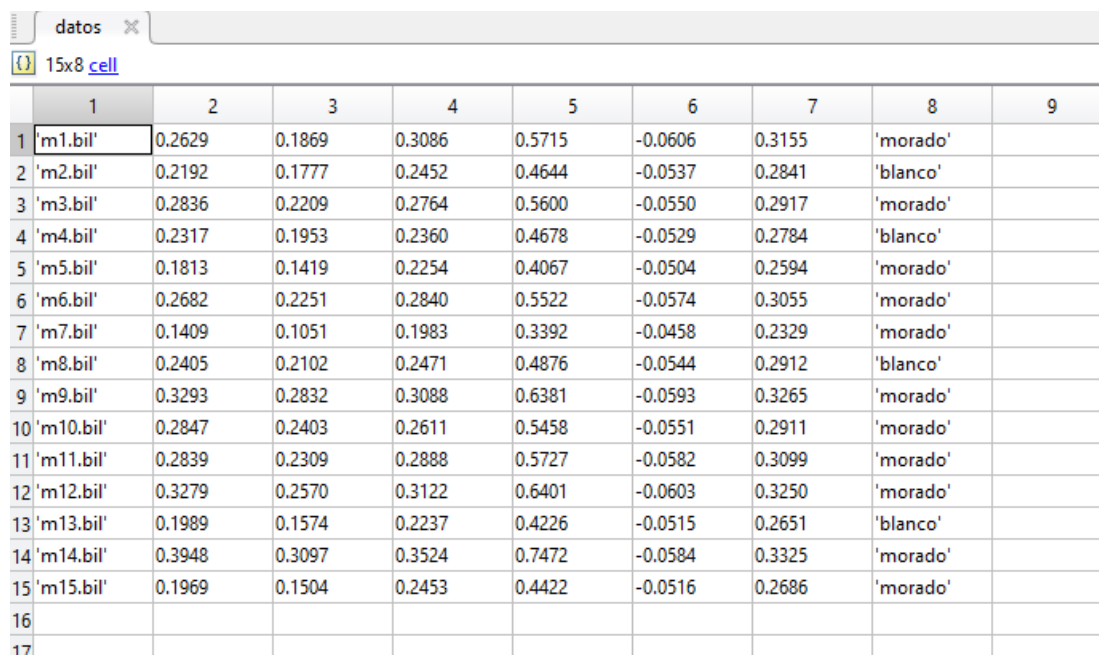
- “Process” (Procesar): Se desarrolla el procesamiento de la imagen y la selección de la región de interés de la cual se extraen los índices espectrales promedio. Con estos datos, se utiliza el clasificador y se obtiene el color interno del grano. En el cuadro izquierdo de la parte inferior de la interfaz se muestra el área de interés seleccionada del grano de cacao, en la ventana derecha se muestra la firma espectral del área seleccionada y en la tabla de la parte inferior de la interfaz, se muestra el nombre del

archivo de la imagen hiperespectral, los 6 índices espectrales y el color interno del grano de cacao.

- Clear data (Borrar datos): Este botón permite borrar las imágenes, gráficos y datos del programa.

A continuación se explica el procedimiento que se realiza en la interfaz de Matlab para la clasificación de grano.

- Primero se da el ingreso de la imagen original, se importa una imagen o varias imágenes ya guardadas en el equipo (Botón: Importar). Luego se activan los botones “Process” y “Clear data”.
- Al presionar la opción de “Process”, se realiza el procesamiento de la imagen en cuestión. Luego en la ventana respectiva aparece el área analizada en el grano y en la tabla aparecen los valores de los índices espectrales y el resultado de la clasificación según el color interno. Los datos de la tabla se guardan automáticamente en el área de trabajo (“Workspace”) en el archivo “datos.mat” (ver Figura 65).



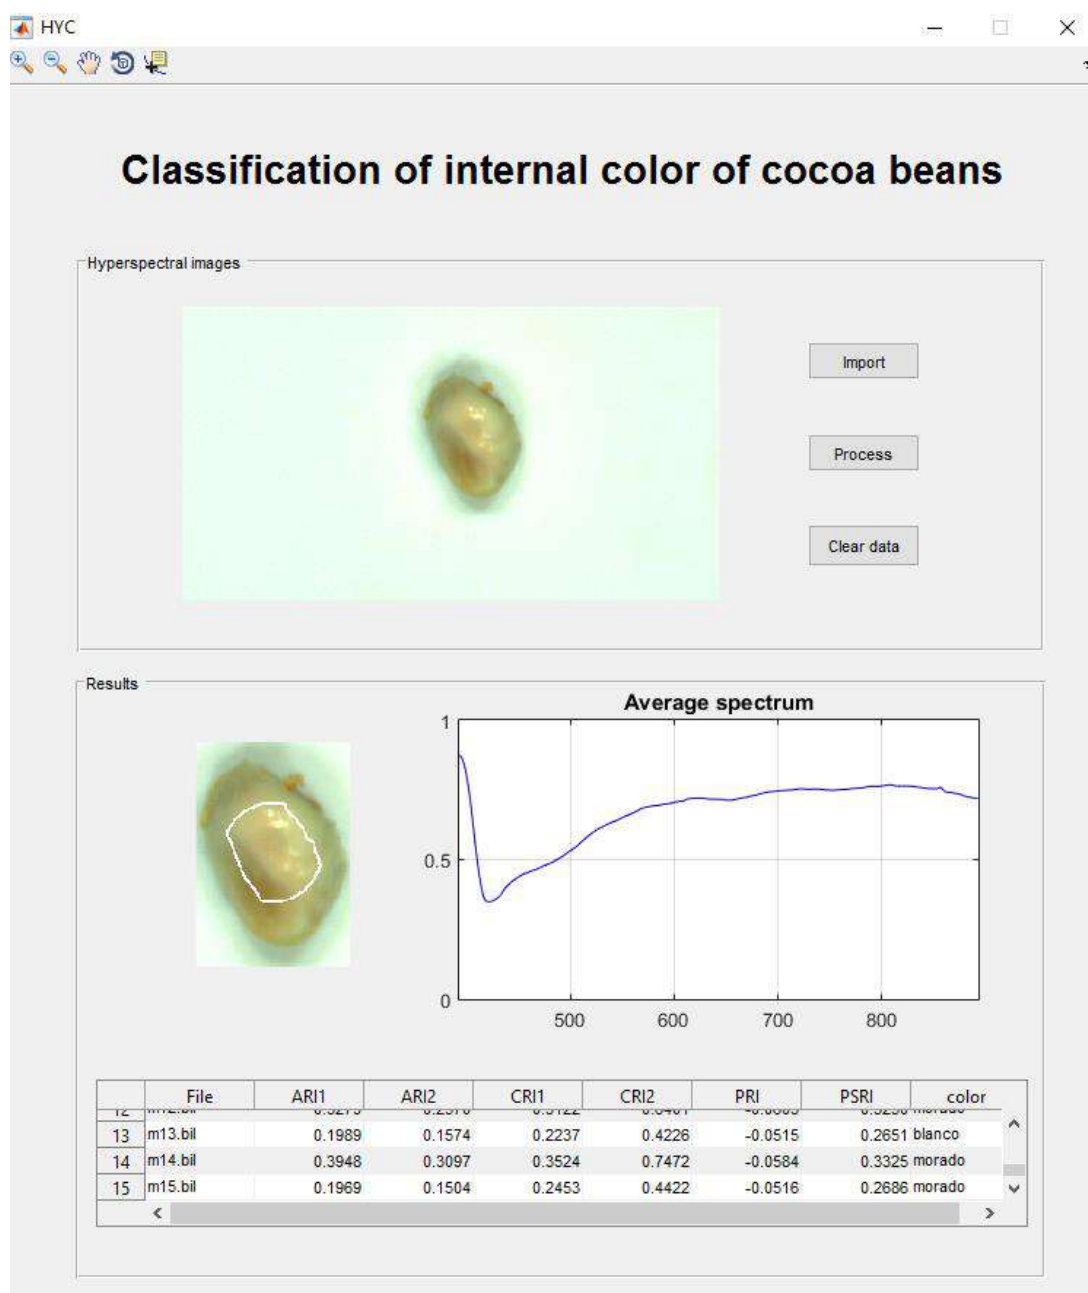
	1	2	3	4	5	6	7	8	9
1	'm1.bil'	0.2629	0.1869	0.3086	0.5715	-0.0606	0.3155	'morado'	
2	'm2.bil'	0.2192	0.1777	0.2452	0.4644	-0.0537	0.2841	'blanco'	
3	'm3.bil'	0.2836	0.2209	0.2764	0.5600	-0.0550	0.2917	'morado'	
4	'm4.bil'	0.2317	0.1953	0.2360	0.4678	-0.0529	0.2784	'blanco'	
5	'm5.bil'	0.1813	0.1419	0.2254	0.4067	-0.0504	0.2594	'morado'	
6	'm6.bil'	0.2682	0.2251	0.2840	0.5522	-0.0574	0.3055	'morado'	
7	'm7.bil'	0.1409	0.1051	0.1983	0.3392	-0.0458	0.2329	'morado'	
8	'm8.bil'	0.2405	0.2102	0.2471	0.4876	-0.0544	0.2912	'blanco'	
9	'm9.bil'	0.3293	0.2832	0.3088	0.6381	-0.0593	0.3265	'morado'	
10	'm10.bil'	0.2847	0.2403	0.2611	0.5458	-0.0551	0.2911	'morado'	
11	'm11.bil'	0.2839	0.2309	0.2888	0.5727	-0.0582	0.3099	'morado'	
12	'm12.bil'	0.3279	0.2570	0.3122	0.6401	-0.0603	0.3250	'morado'	
13	'm13.bil'	0.1989	0.1574	0.2237	0.4226	-0.0515	0.2651	'blanco'	
14	'm14.bil'	0.3948	0.3097	0.3524	0.7472	-0.0584	0.3325	'morado'	
15	'm15.bil'	0.1969	0.1504	0.2453	0.4422	-0.0516	0.2686	'morado'	
16									
17									

**Figura 65.** Matriz “datos.mat”.

Fuente: Elaboración propia.

En la Figura 66, se observa la interfaz desarrollada en Matlab donde se presentan los índices espectrales y el color interno de granos de cacao.





**Figura 66.** Interfaz gráfica para la clasificación según color interno.  
Fuente: Elaboración propia.





## Capítulo 4

### Aplicación de sistema de imágenes hiperespectrales

#### 4.1 Material de estudio e identificación


##### 4.1.1 Antocianina

Las antocianinas son compuestos fenólicos que se producen comúnmente en el reino vegetal. Son el grupo más importante de pigmentos flavonoides de la familia de los polifenoles, solubles en agua y responsables de las coloraciones rojas, azules y púrpuras de algunas flores, frutos, hojas y raíces de plantas (Aceituno, 2010). Factores ambientales como la luz, la temperatura y la altitud afectan la concentración de antocianinas.

El color de las antocianinas puede ser influenciado por la estructura de las antocianinas, la acidez del medio ambiente y la presencia de metales. La intensidad y el tipo de color de las antocianinas se definen por el número y orientación de los grupos hidroxilo y metoxilo de la molécula. Un incremento en los grupos hidroxilo produce coloraciones azules y un incremento en los grupos metoxilo produce coloraciones rojas (He & Giusti, 2010). Sin embargo, los cambios de color más notorios son aquellos que dependen del pH. A pH = 3, el pigmento está presente como sales de flavilio de color rojo, a pH = 8, es de color violeta, y a pH = 11, de color azul (Fuentes, 2005).

El término antocianina proviene de las palabras griegas “anthos” (flor) y “kyanos” (azul oscuro), y fue introducido en 1835 por Marquant para designar los pigmentos azules de las flores (Aguilera, 2009). Luego se descubrió el color púrpura, violeta, magenta, y todos los tonos de rojo, rosado y escarlata, como pigmentos químicamente similares a las antocianinas de Marquant (Aroni, 2013).

Las antocianinas son metabolitos secundarios polifenólicos. Su estructura se asemeja al esqueleto de carbono C6-C3-C6 de otros flavonoides naturales y tiene el mismo origen biosintético, pero se diferencian en que absorben fuertemente en la región visible del espectro (Aroni, 2013). También las antocianinas se definen como glucósidos de las antocianidinas (ver Figura 67), es decir, están constituidas por una molécula de antocianidina, que es la aglicona, a la que se le une un azúcar a través de un enlace  $\beta$ -glucosídico (Aguilera, 2009).



**Figura 67.** Formula de Antocianidinas (cationes flavilium).

Fuente: Aguilera, 2009.

Las antocianinas son importantes como colorantes alimenticios por su capacidad de mejorar la apariencia total, y el gran beneficio para la salud humana. Algunos investigadores se han enfocado sobre los beneficios de las antocianinas en la salud, especialmente su actividad antioxidante, antimutagénica y quimopreventiva, que contribuyen a la reducción de enfermedades crónicas, inhibición del crecimiento de las células cancerígenas, prevención de algunas cardiopatologías, reducción de la enfermedad coronaria, reducción del riesgo de accidente cerebrovascular, y reducción de efectos antitumorales, antiinflamatorios y antidiabéticos; además del mejoramiento de la agudeza visual y del comportamiento cognitivo (Aguilera, 2009; He & Giusti, 2010).

#### 4.1.1.1 Detección e identificación

La determinación cualitativa y cuantitativa de las antocianinas puede lograrse mediante varios métodos, entre ellos, la espectroscopia ultravioleta-visible (UV-Vis), método de pH diferencial, resonancia magnética nuclear (NMR), espectroscopia de infrarrojo cercano (NIR), Espectrometría de Masas (MS), Cromatografía Líquida de Alto Rendimiento (HPLC), colorimetría, electroforesis capilar (CE) e imágenes hiperespectrales.

Cuando un haz de luz llega a la fruta, ocurren fenómenos como la reflexión, absorción, transmisión y dispersión de la luz. Según (Birth, 1976), aproximadamente el 4% de la radiación incidente se refleja en la superficie externa como reflectancia especular o brillo. El resto de la radiación (96%) penetra en el tejido en diferentes direcciones donde es absorbido por los constituyentes o dispersado por pequeñas interfaces dentro del tejido. La profundidad de penetración de luz varía según la longitud de onda y la energía luminosa, y se define como la profundidad a la que se redujo la luz incidente en un 99% (Qin & Lu, 2008). La absorción de la luz está relacionada con las estructuras químicas de los constituyentes de la fruta. Los absorbentes principales en el intervalo de longitud de onda visible son los pigmentos tales como clorofilas, carotenoides, y antocianinas mientras que el agua es el principal absorbente en la región del infrarrojo cercano. La luz que penetra más profundamente en los tejidos es modificada por las absorciones seleccionadas de los constituyentes y, por lo tanto, contiene información de composición útil (Bureau, 2009).

La evaluación no destructiva de los pigmentos en los frutos se complica por la superposición de la absorción de la luz por diferentes pigmentos y la relación no lineal de la reflectancia frente al contenido de pigmento en las bandas de absorción máxima. Las antocianinas presentan máximos de absorción tanto en la región visible (490 - 550 nm) como en la ultravioleta (260-280 nm). Las longitudes de onda de estos picos de absorbancia pueden diferir ligeramente dependiendo de la estructura de cada antocianina y del pH. La absorción de antocianina generalmente se manifiesta como un hombro o una banda cerca de 540 - 550 nm por lo general superpuesta con la absorción de clorofila y carotenoides (Gitelson et al., 2001; Merzlyak et al., 2003a).

#### **4.1.1.2 Función de antocianina en granos de cacao**

Los granos de cacao son una rica fuente de polifenoles (aproximadamente 15% del peso del grano seco). Se distinguen tres grupos de polifenoles en el cacao: catequinas o flavan-3-ol (aproximadamente 37%), antocianinas (aproximadamente 4%) y proantocianidinas (aproximadamente 58%). La fracción antocianina consiste principalmente en cianidina-3- $\alpha$ -L-arabinosida y cianidina-3- $\beta$ -D-galactosida. Los polifenoles son compuestos en los granos de cacao almacenados en las células pigmentarias de los cotiledones y dependiendo de la cantidad de antocianinas, esas células son de color blanco a púrpura oscuro (Wollgast & Anklam, 2000).

Las antocianinas se hidrolizan a antocianidinas y azúcares (galactosa y arabinosa) por glicosidasa durante la fermentación del cacao (Afoakwa, 2010). Esto explica el blanqueamiento del color púrpura de los cotiledones. Durante la fermentación y secado, el contenido de polifenoles disminuye a medida que algunos se difunden fuera de los granos, y otros se oxidan y polimerizan a compuestos insolubles de alto peso molecular (taninos) (Pettipher, 1986; Wollgast & Anklam, 2000).

Las antocianinas generalmente desaparecen rápidamente durante el proceso de fermentación, por ejemplo, el 93% se perdieron después de cuatro días de fermentación (Afoakwa et al., 2013) y el color de los granos cambia de pizarrosa a púrpura a marrón. Este cambio de color se usa para predecir el sabor de los granos de cacao. Por lo tanto, el contenido de antocianinas se considera como un buen índice para la determinación del grado de fermentación del grano de cacao (Pettipher, 1986; Wollgast & Anklam, 2000).

La fermentación es un aspecto crucial del procesamiento primario del cacao ya que resulta en la formación de precursores de compuestos aromáticos esenciales a la vez que provoca una disminución de la astringencia y el amargor. Los granos poco fermentados son morados o pizarrosos debido a la presencia de pigmentos antocianinos, mientras que fermentan completamente los granos son de color marrón y los frijoles sobrefermentados tienen un color oscuro opaco (Pettipher, 1986).

La cantidad de antocianinas presentes en el grano de cacao depende del cultivar de la planta, el origen geográfico y las condiciones ambientales. Los granos de cacao Forastero no fermentados tienen un color violeta o morado debido a la presencia de antocianinas en los cotiledones. Los granos Criollo contienen aproximadamente dos tercios de la cantidad de polifenoles encontrados en Forastero, pero no antocianinas, por eso fermentan más rápido (Wollgast & Anklam, 2000).

#### 4.1.2 Índices espectrales de vegetación

Los índices de vegetación pueden ser calculados a partir de las salidas de tensión del sensor, valores de luminancia, valores de reflectancia y números digitales de satélite. Cada uno es correcto, pero cada uno dará un valor de índice diferente para las mismas condiciones (Jackson & Huete, 1991).

El principio del desarrollo del índice es seleccionar determinados rangos de longitud de onda de reflectancia o transmitancia parcial, cuyos coeficientes de variación se correlacionan altamente con propiedades vegetales. La información puede ser recolectada estimando las posiciones de los máximos de absorción o la firma de todo un espectro.

Los índices espectrales pueden consistir en una longitud de onda de reflectancia única, diferencias o relaciones entre longitudes de onda, derivadas, o índices relacionados con el borde rojo que es un cambio brusco en la reflectancia entre 680 y 750 relacionado con el contenido de clorofila. El uso de relaciones o diferencias se prefiere generalmente porque la reflectancia a una determinada longitud de onda puede ser afectada por la irradiancia variable, efectos de fondo, sensores u otros factores (Von, 2012).

Los índices de vegetación se han utilizado mucho en la teledetección para vigilar los cambios temporales asociados con la vegetación. Los índices se correlacionan bien con diferentes parámetros de vegetación como densidad o cubierta vegetal, biomasa, índice de área foliar, actividad fotosintética, uso del agua, estrés de la planta, sanidad vegetal, la concentración de pigmento, nitrógeno foliar, y producción de cultivos (Wiegand et al., 1991).

Un considerable número de índices de vegetación están basados en el alto contraste entre la banda del rojo y la del infrarrojo cercano (Tucker, 1979; Jackson & Huete, 1991). El Índice de Vegetación de Diferencia Normalizada (NDVI), introducido por (Rouse et al., 1974), es el índice más utilizado en la estimación remota del contenido de clorofila (Qin & Lu, 2008) y en estudios de evaluación de la dinámica vegetal (Von, 2012). El NDVI es un indicador aceptable para la madurez del fruto, debido a la alta variabilidad de los contenidos de clorofila-a durante la madurez del fruto (Zude, 2003).

El NDVI se define como la diferencia entre los valores de reflectancia de infrarrojo cercano y rojo divididos por su suma (Von, 2012).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Dónde: NIR = reflectancia correspondiente al infrarrojo cercano, RED = reflectancia correspondiente al rojo.

Se han desarrollado varios índices de vegetación que reducen las observaciones multibanda a un índice numérico. Con más de 150 índices diferentes, la salida deseada y otras condiciones determinarán el tipo de índice utilizado. Algunos de los índices más populares incluyen el Índice de Vegetación de Diferencia Normalizada (NDVI) (Rouse et al., 1974), el Índice de Vegetación Ajustada al Suelo (SAVI) (Huete, 1988) y el Índice de Relación de Vegetación (RVI) (Jordan, 1969; Rouse et al., 1974).

A continuación se mencionan algunos de los índices de vegetación más importantes:

- ARVI: Índice de Vegetación Resistente a la Atmósfera
- CAI: Absorción de Clorofila Integral
- CARI: Índice de Reflectancia de Absorción de Clorofila
- CIg: Índice de Clorofila
- DVI: Índice de Vegetación de Diferencia
- EVI: Índice de Vegetación Mejorado
- MCARI: Índice Modificado de Reflectancia de Absorción de Clorofila
- NDVI: Índice de Vegetación de Diferencia Normalizada
- NDWI: Índice de Agua de Diferencia Normalizada
- NPCI: Índice de la relación Normalizada de Clorofila y Pigmento
- OSAVI: Índice Optimizado de Vegetación Ajustado al Suelo
- PSRI: Índice de Reflectancia de la Senescencia de la Planta
- RVI: Índice de Relación de Vegetación, también conocido como SR
- SAVI: Índice de Vegetación Ajustada al Suelo
- SR: Relación Simple, también conocida como RVI
- TCARI: Índice Transformado de Reflectancia de Absorción de Clorofila
- TSAVI: Índice Transformado de Vegetación Ajustada al Suelo
- WBI: Índice de Banda de Agua

#### **4.1.2.1 Índices del programa**

Los índices hiperespectrales de vegetación calculados por SpectrononPro se presentan en la Tabla 5, también se presentan las ecuaciones de cada uno de los índices.

**Tabla 5.** Índices Hiperespectrales de Vegetación en SpectrononPro.

<b>Índice Hiperespectral de Vegetación</b>	<b>Ecuación en SpectrononPro</b>
Índice de Reflectancia de Antocianina 1	$ARI1 = \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}}$
Índice de Reflectancia de Antocianina 2	$ARI2 = \rho_{800} \left( \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \right)$
Índice de Vegetación Resistente a la Atmósfera	$ARVI = \frac{NIR - (Red - \gamma(Blue - Red))}{NIR + (Red - \gamma(Blue - Red))}$
Índice de Reflectancia de Carotenoide 1	$CRI2 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}}$
Índice de Reflectancia de Carotenoide 2	$CRI2 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{700}}$
Índice de Vegetación Mejorado	$EVI = \frac{NIR - Red}{NIR + 6.0 \cdot Red - 7.5 \cdot Blue + 1}$
Índice Modificado de Reflectancia de Absorción de Clorofila	$MCARI = \rho_{700} - \rho_{670} - 0.2(\rho_{700} - \rho_{550}) \left( \frac{\rho_{700}}{\rho_{670}} \right)$
Índice de Vegetación Normalizado Modificado de Borde Rojo	$MRENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2 \cdot \rho_{445}}$
Índice Modificado de Relación Simple de Borde Rojo	$MRESR = \frac{\rho_{750} - \rho_{445}}{\rho_{705} - \rho_{445}}$
Índice de Vegetación de Diferencia Normalizada	$NDVI = \frac{NIR - Red}{NIR + Red}$
Índice de Reflectancia Fotoquímica	$PRI = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}}$
Índice de Reflectancia de la Senescencia de la Planta	$PSRI = \frac{\rho_{680} - \rho_{500}}{\rho_{750}}$
Índice de Vegetación de Diferencia Normalizada de Borde Rojo	$RENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$
Índice de Relación Simple	$SR = \frac{NIR}{Red}$
Índice de Pigmentación Insensible a la Estructura	$SIPI = \frac{\rho_{800} - \rho_{445}}{\rho_{800} + \rho_{680}}$
Índice Transformado de Reflectancia de Absorción de Clorofila	$TCARI = 3 \left[ \rho_{700} - \rho_{670} - 0.2(\rho_{700} - \rho_{550}) \left( \frac{\rho_{700}}{\rho_{670}} \right) \right]$
Índice Vogelmann Borde Rojo 1	$VREI1 = \frac{\rho_{740}}{\rho_{720}}$
Índice Vogelmann Borde Rojo 2	$VREI2 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} - \rho_{726}}$
Índice Vogelmann Borde Rojo 3	$VREI3 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{720}}$
Índice de Banda de Agua	$WBI = \frac{\rho_{970}}{\rho_{900}}$

Fuente: Elaboración propia.

#### 4.1.2.2 Índices utilizados

Se han ideado modelos conceptuales que permiten la evaluación no destructiva del contenido total de clorofila en hojas y frutos superiores. Esencialmente, los mismos modelos se han utilizado con éxito para el análisis no destructivo del contenido de carotenoides y antocianinas (Gitelson et al., 2002a; Merzlyak et al., 2003a, 2003b, 2005). El análisis del contenido de antocianinas requiere la eliminación de los efectos por carotenoides y clorofilas (Merzlyak et al., 2003a). Se diseñaron índices de vegetación para estimar el contenido de antocianinas de forma no destructiva y estos índices incluyen relaciones entre rangos verdes, rojos, de borde rojo y NIR de los espectros (Gitelson et al., 2001).

##### a) ARI1-ARI2

El ARI específico de antocianina fue desarrollado por (Gitelson et al., 2001) para determinar el contenido de antocianina. En (Gitelson et al., 2001), los espectros de absorción y reflectancia de hojas de arce, cotoneaster, cornejo y pelargonium con un amplio rango de contenido y composición de pigmento (antocianina, clorofila y carotenoide) se estudiaron en el rango visible e infrarrojo cercano para revelar características espectrales específicas de antocianina en las hojas. La principal característica espectral de la absorción de antocianina fue un pico alrededor de 550 nm. Se desarrolló una técnica para restar la contribución de clorofila a la reflectancia en esta región espectral y recuperar el contenido de antocianina. El índice de reflectancia de antocianina en la forma  $ARI = (R_{550})^{-1} - (R_{700})^{-1}$ , donde  $(R_{550})^{-1}$  y  $(R_{700})^{-1}$  son reflectancias inversas a 550 y 700 nm, respectivamente, permitieron una estimación precisa de la acumulación de antocianinas, incluso en mínimas cantidades, en senescencia intacta y hojas estresadas. El primer término es responsable tanto de la absorción de clorofila como de antocianina, y el último de la absorción de clorofila.

En el rango de antocianina de 0.3 a 100 nmol/cm<sup>2</sup>, se sugiere usar ARI en forma de:  $(R_{550})^{-1} - (R_{700})^{-1}$  o  $R_{NIR} \cdot [(R_{550})^{-1} - (R_{700})^{-1}]$ , donde  $R_{NIR}$  es la reflectancia en el rango NIR superior a 750 nm

En el rango de antocianina de 0.3 a 25 nmol/cm<sup>2</sup>, el error estándar de la estimación de antocianina por ambos índices no excedió 3 nmol/cm<sup>2</sup>, y en todo el rango 0.3 - 100 nmol/cm<sup>2</sup>, estaba dentro de 11 nmol/cm<sup>2</sup>.

Para un contenido de antocianina mayor a 25 nmol/cm<sup>2</sup>, cuando  $ARI > 0.1$ , se sugiere usar cualquiera:  $(R_{550})^{-1}$  o  $R_{NIR}/R_{550}$ . Se logra la estimación de antocianina con un error de menos de 3.9 nmol/cm<sup>2</sup>.

$$ARI1 = (R_{550})^{-1} - (R_{700})^{-1}$$

El ARI2 es una modificación del ARI1 que detecta mayores concentraciones de antocianinas en la vegetación.

$$ARI2 = R_{800}[(R_{550})^{-1} - (R_{700})^{-1}]$$

## b) CRI1-CRI2

En (Gitelson et al., 2002a), se investigó la reflectancia espectral de hojas de arce, castaño y haya en una amplia gama de contenido y composición de pigmentos para diseñar una técnica no destructiva para la estimación del contenido total de carotenoides en hojas superiores de plantas. Las reflectancias en tres bandas espectrales,  $510 \pm 5$  nm,  $550 \pm 15$  nm o  $700 \pm 7.5$  nm y el rango infrarrojo cercano a 750 nm son suficientes para estimar el contenido total de carotenoides en hojas de plantas de forma no destructiva con un error cuadrático medio menor de  $1.75$  nmol/cm<sup>2</sup>.

Por lo tanto, para la estimación del contenido de carotenoides, se diseñó y usó el índice CRI, que representa la diferencia entre la reflectancia recíproca a 510 nm, donde tanto los carotenoides como la clorofila afectan la reflectancia, y en 550 o 700 nm, donde solo la clorofila afecta la reflectancia:

$$\begin{aligned} CRI_{550} &= (R_{510})^{-1} - (R_{550})^{-1} \\ CRI_{700} &= (R_{510})^{-1} - (R_{700})^{-1} \end{aligned}$$

En los índices anteriores, el primer término es responsable tanto de la absorción de clorofila como de carotenoides y el último término es responsable de la absorción de clorofila. El índice CRI2 proporciona mejores resultados en áreas de alta concentración de carotenoides. Debe mencionarse, sin embargo, que el CRI no es aplicable a los tejidos vegetales que contienen antocianina (Merzlyak et al., 2003b).

## c) PRI

El índice PRI fue originalmente desarrollado por (Gamon et al., 1992), donde se presenta el índice PRI aislado a partir de mediciones espectrales de banda de onda estrecha de doseles de girasol. Este índice se correlaciona con el estado de epoxidación de los pigmentos del ciclo de xantofila y con la eficacia de la fotosíntesis y estrés de nitrógeno de los doseles, pero no en estrés hídrico los de doseles sometidos a marchitez del mediodía. Este índice utiliza la reflectancia a 531 nm y a una longitud de onda de referencia para minimizar las complicaciones asociadas con los cambios diurnos del ángulo solar. Junto con otros métodos, este índice puede conducir a estimaciones mejoradas remotas y basadas en tierra de la función fotosintética del dosel.

$$PRI = \frac{(R_{531} - R_{570})}{(R_{531} + R_{570})}$$

Donde  $R_{531}$  es la reflectancia a 531 nm y  $R_{570}$  es la reflectancia a 570 nm. La formulación de este PRI es análoga a la de NDVI (Tucker, 1979).

## d) PSRI

En (Merzlyak et al., 1999), espectros de reflectancia en el rango visible e infrarrojo cercano del espectro, adquiridos para hojas de arce, castaño, papa, hojas de coleo, limón y manzana fueron estudiados. Se encontró que tanto la senescencia de la hoja como la maduración de la fruta afectan la diferencia entre la reflectancia (R) cercana a 670 y 500 nm ( $R_{678} - R_{500}$ ), dependiendo de la composición del pigmento.



Se concluyó que el índice PSRI en la forma  $(R_{678} - R_{500})/R_{750}$  era sensible a la relación carotenoide/clorofila, y se usó como una medida cuantitativa de la senescencia de la hoja y la maduración de la fruta. Los cambios en el índice se siguieron durante la senescencia de la hoja, y la maduración de la fruta de forma natural e inducida por etileno. El PSRI se puede utilizar para estimar el inicio, el estado, las velocidades relativas y la cinética de los procesos de senescencia/maduración.


$$PSRI = \frac{(R_{680} - R_{500})}{R_{750}}$$

### 4.1.3 Modelo de clasificación SVM

El aprendizaje supervisado implica analizar un conjunto dado de observaciones etiquetadas (conjunto de entrenamiento) para predecir las etiquetas de los datos futuros no etiquetados (conjunto de prueba). Específicamente, el objetivo es aprender alguna función que describa la relación entre las observaciones y sus etiquetas.

La máquina del vector de soporte (SVM) fue desarrollado por (Cortes & Vapnik, 1995) y es un método supervisado de aprendizaje estadístico no paramétrico con buena capacidad de generalización. El concepto básico de SVM es encontrar el hiperplano o conjunto de hiperplanos de separación óptimo en un espacio de alta dimensión resultando una tasa de clasificación errónea mínima (Zhang et al., 2014). El hiperplano óptimo se construye con el máximo margen entre las clases y vectores de soporte y se reduce el número de valores atípicos, que se encuentran entre las líneas de margen (Yang, 2013). En la Figura 68, se muestra un ejemplo de la aplicación de un modelo SVM.

La SVM no necesita un gran número de muestras para ser entrenada y no se ve afectada por valores atípicos. SVM ha demostrado su excelente desempeño para resolver problemas de clasificación en varios campos, entre ellos sistemas espectrales (Teye et al., 2014; Zulfahrizal et al., 2016).



**Figura 68.** Un ejemplo de un problema separable en un espacio bidimensional. Los vectores de soporte, marcados con cuadrados grises, definen el margen de separación más grande entre las dos clases.

Fuente: Cortes & Vapnik, 1995.

## 4.2 Metodología

A continuación se explicará la metodología utilizada para el análisis de las imágenes hiperespectrales de granos de cacao.

### 4.2.1 Entrenamiento y validación

- Adquisición de imágenes hiperespectrales: Se capturan imágenes hiperespectrales de 120 granos de cacao en la etapa de cosecha, como el que se observa en la Figura 69. En el desarrollo de esta tesis, las muestras se dispusieron en la plataforma de desplazamiento del sistema de adquisición de imagen hiperespectrales. Mediante el software se procedió al escaneo de las muestras; visualizando una imagen en pseudo RGB. Esta imagen se procedió a almacenar en el disco duro del ordenador en formato \*.bil.



**Figura 69.** Imagen hiperespectral de grano de cacao.  
Fuente: Elaboración Propia.

- Procesamiento de imágenes hiperespectrales: En este paso se seleccionó una región de interés que consiste en una figura circular en el centro del grano que asemeja los bordes del grano y a partir de esta sección central se calcularon los seis índices espectrales elegidos (ARI1, ARI2, CRI1, CRI2, PRI, PSRI). Para poder apreciar el color interno de los granos, estos se cortaron transversalmente después de capturar su imagen hiperespectral, como se observa en la Figura 70.



**Figura 70.** Imagen hiperespectral de grano de cacao cortado transversalmente.  
Fuente: Elaboración Propia.

La selección de la sección central en los granos de cacao se realizó definiendo los bordes del grano del cacao con imágenes binarizadas y determinando el centro del grano con la función “Regionprops” de Matlab.

El conjunto de índices obtenidos en las distintas imágenes se dispuso en una matriz, denominada base de datos, de dimensiones 120 x 7; donde 120 es el número de imágenes, y 7, los índices espectrales y la clase definida manualmente por las imágenes de los granos cortados.

Se analizó si el contenido de pigmento puede relacionarse con cambios en la firma espectral de diferentes granos de cacao, tal como se observa en la Figura 71 no se aprecia diferencias notorias entre los espectros de granos morados y blancos.

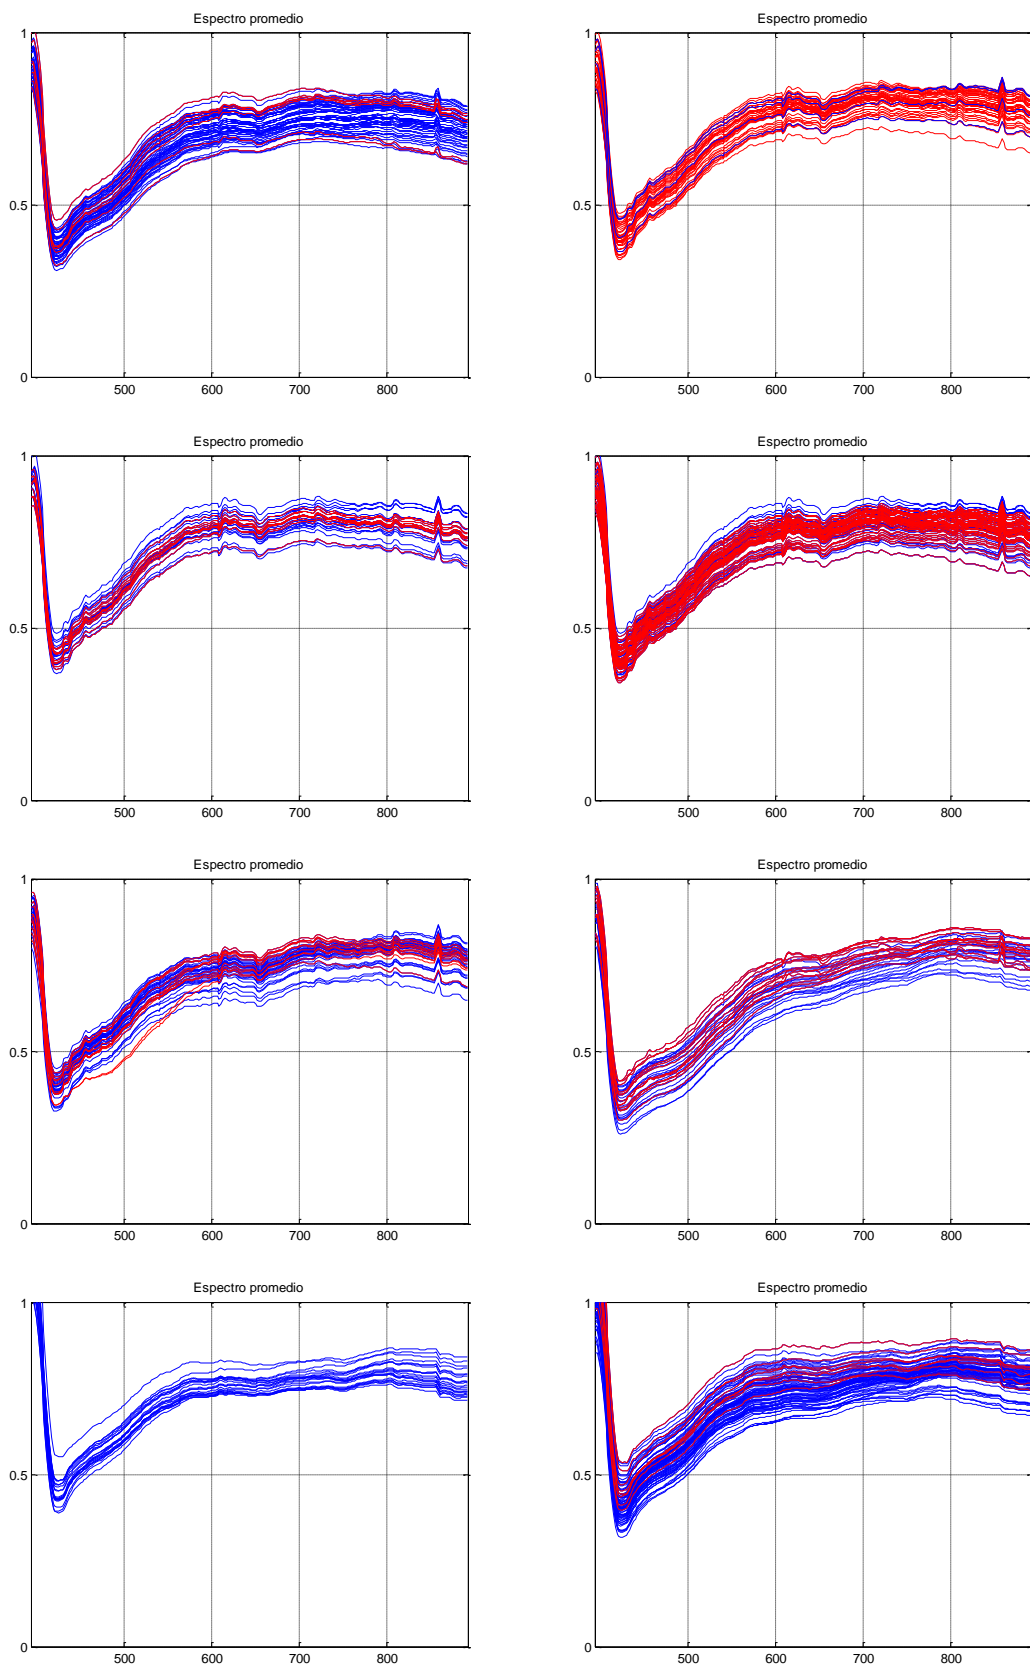
- Determinación de índices espectrales: Debido a que las firmas espectrales no permiten apreciar la influencia de los pigmentos en los granos de cacao se estimó adecuado analizar los índices espectrales relacionados en el contenido de pigmentos. Se propusieron y calcularon seis índices espectrales, véase Tabla 6.

**Tabla 6.** Determinación de índices espectrales.

Índice Hiperespectral de Vegetación	Ecuación
Índice de Reflectancia de Antocianina 1	$ARI1 = \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}}$
Índice de Reflectancia de Antocianina 2	$ARI2 = \rho_{800} \left( \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \right)$
Índice de Reflectancia de Carotenoide 1	$CRI1 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}}$
Índice de Reflectancia de Carotenoide 2	$CRI2 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{700}}$
Índice de Reflectancia Fotoquímica	$PRI = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}}$
Índice de Reflectancia de la Senescencia de la Planta	$PSRI = \frac{\rho_{680} - \rho_{500}}{\rho_{750}}$

Fuente: Elaboración propia.

- Entrenamiento y validación de clasificador: Se realizaron los procedimientos necesarios para definir cuál modelo de clasificación era el más eficiente según la base de datos. El modelo más eficiente fue el modelo Linear SVM (Máquina de vector de soporte lineal) con un porcentaje promedio de acierto de 85.7%. Definido este clasificador se almacenó en formato \*.mat



**Figura 71.** Firmas espectrales de granos de cacao de 8 distintas vainas.

Línea azul: grano morado - Línea roja: grano blanco.

Fuente: Elaboración Propia.

#### 4.2.2 Aplicación

En la aplicación del sistema, se usó granos elegidos en el mismo día de cosecha que los granos que se utilizaron para el entrenamiento del clasificador; posteriormente se obtuvieron y procesaron las imágenes hiperespectrales. En cada imagen hiperespectral se seleccionó la región de interés anteriormente definida, se extrae su informaron espectral y se calcula sus índices espectrales. Estos índices se usaron, mediante el clasificador entrenado en la etapa anterior, para determinar el color interno de los granos de cacao. En las siguientes líneas se profundizara cada paso.

- Clasificación visual: Los granos de cacao fueron clasificadas visualmente de acuerdo a su color interno (morado/blanco).
- Adquisición y corrección de imágenes: Las imágenes de cada uno de los granos de cacao de validación (60) fueron adquiridas y procesadas tal como se hizo para las muestras de entrenamiento.
- Procesamiento: En este paso se seleccionó una región de interés, una figura circular en el centro que asemeja los bordes de los granos de cacao. Seleccionada la región de interés se determinó los perfiles espectrales de los pixel que las conformaba tal como se hizo para las muestras de entrenamiento.
- Determinación de índices: A partir de los perfiles espectrales, obtenidos en el paso anterior, se calcularon sus índices espectrales, de acuerdo a la Tabla 6. Estos índices caracterizaron cada uno de los pixeles de la sección central de los granos de cacao como paso previo a su clasificación por el sistema entrenado.
- Aplicación de clasificador entrenado: La clasificación de los pixeles de cada grano se realizó usando el clasificador Linear SVM.
- Evaluación del sistema. El sistema desarrollado en esta investigación fue comparado con los resultados por la clasificación visual, en este sentido se determinó que el promedio de porcentaje de acierto de 85.7% es aceptable.

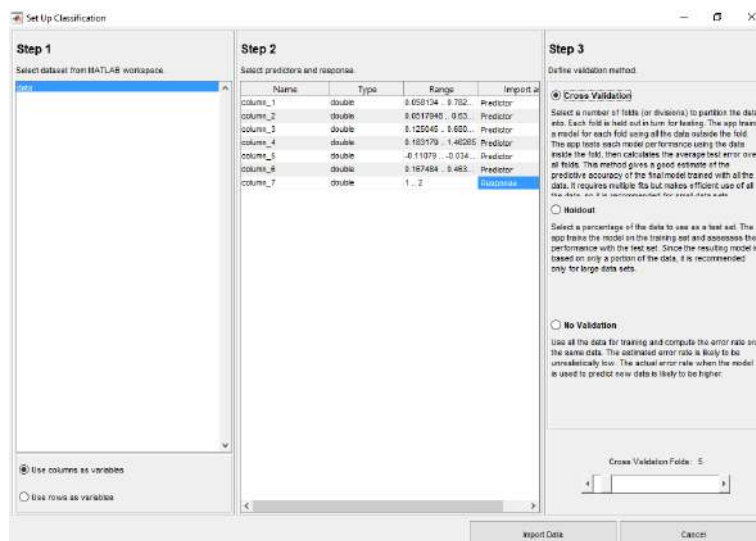


## Capítulo 5

### Resultados y discusión

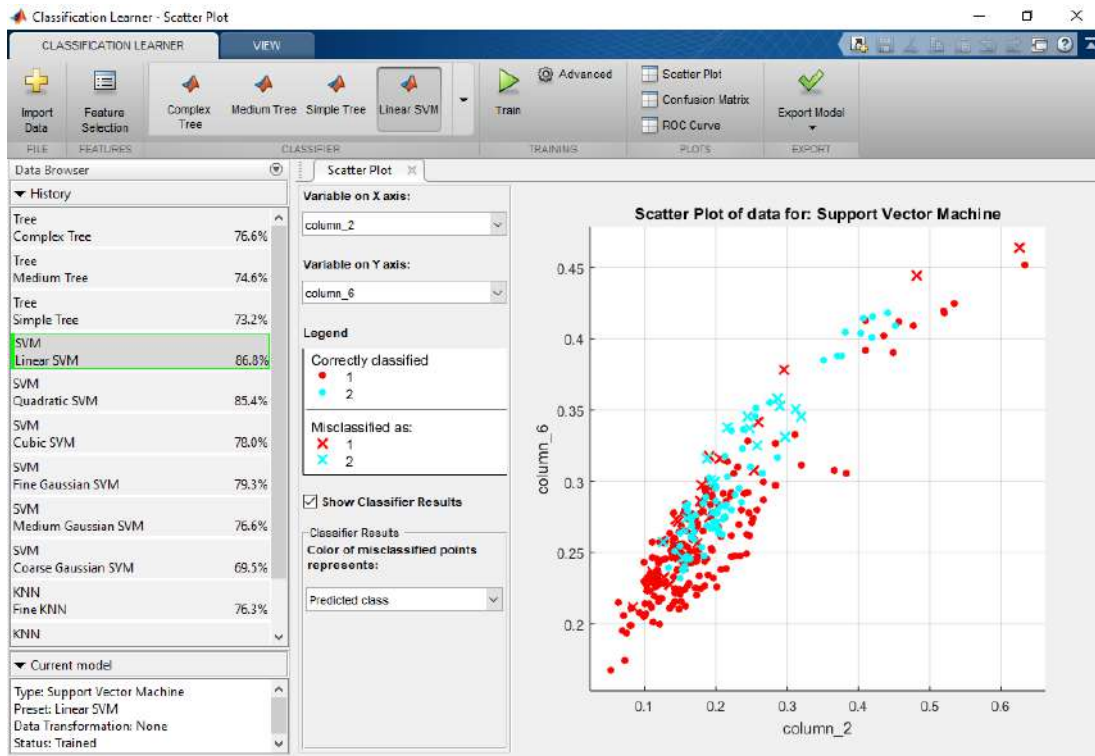
El rendimiento de un sistema de clasificación se basa en la medida del acierto (porcentaje de muestras bien clasificadas) de un conjunto de datos. Si entrenamos un clasificador con una serie de muestras, no podemos comprobar su eficacia con las mismas muestras, pues no se obtiene un resultado verdadero. Por ello, en nuestro caso hemos utilizado un conjunto de entrenamiento y otro conjunto de validación del mismo día de cosecha. En la Figura 72, se muestra la selección de base de datos (matriz) y el método de validación en Matlab.

Además en la aplicación de Matlab llamada “Classification Learner” se comprobó el porcentaje de acierto de distintos modelos de clasificación con la estrategia de validación cruzada, como se observa en la Figura 73, para tener una idea del rendimiento de cada uno de los modelos incluidos árboles de decisión, análisis discriminante, máquinas de vectores de soporte, regresión logística, vecinos más cercanos y la clasificación de conjuntos. Los métodos de validación cruzada (“cross-validation”) consisten en dividir el conjunto de datos en varias partes, e ir utilizándolas iterativamente como conjuntos de entrenamiento y prueba, dando como resultado la media de los aciertos parciales. En nuestro caso, utilizamos 5 conjuntos y se le denomina “5-fold cross-validation”.



**Figura 72.** Selección de base de datos (matriz) y método de validación.

Fuente: Elaboración propia.



**Figura 73.** Comprobación de acierto de distintos modelos de clasificación.

Fuente: Elaboración propia.

## 5.1 Entrenamiento y validación

El total de imágenes hiperespectrales de granos de cacao que conformo el conjunto de entrenamiento y el de validación fue 300 obtenidos de 8 bellotas. La distribución de granos de cacao utilizados para el entrenamiento y validación se presenta en la Tabla 7.

**Tabla 7.** Distribución de granos de cacao utilizados para el entrenamiento y validación.

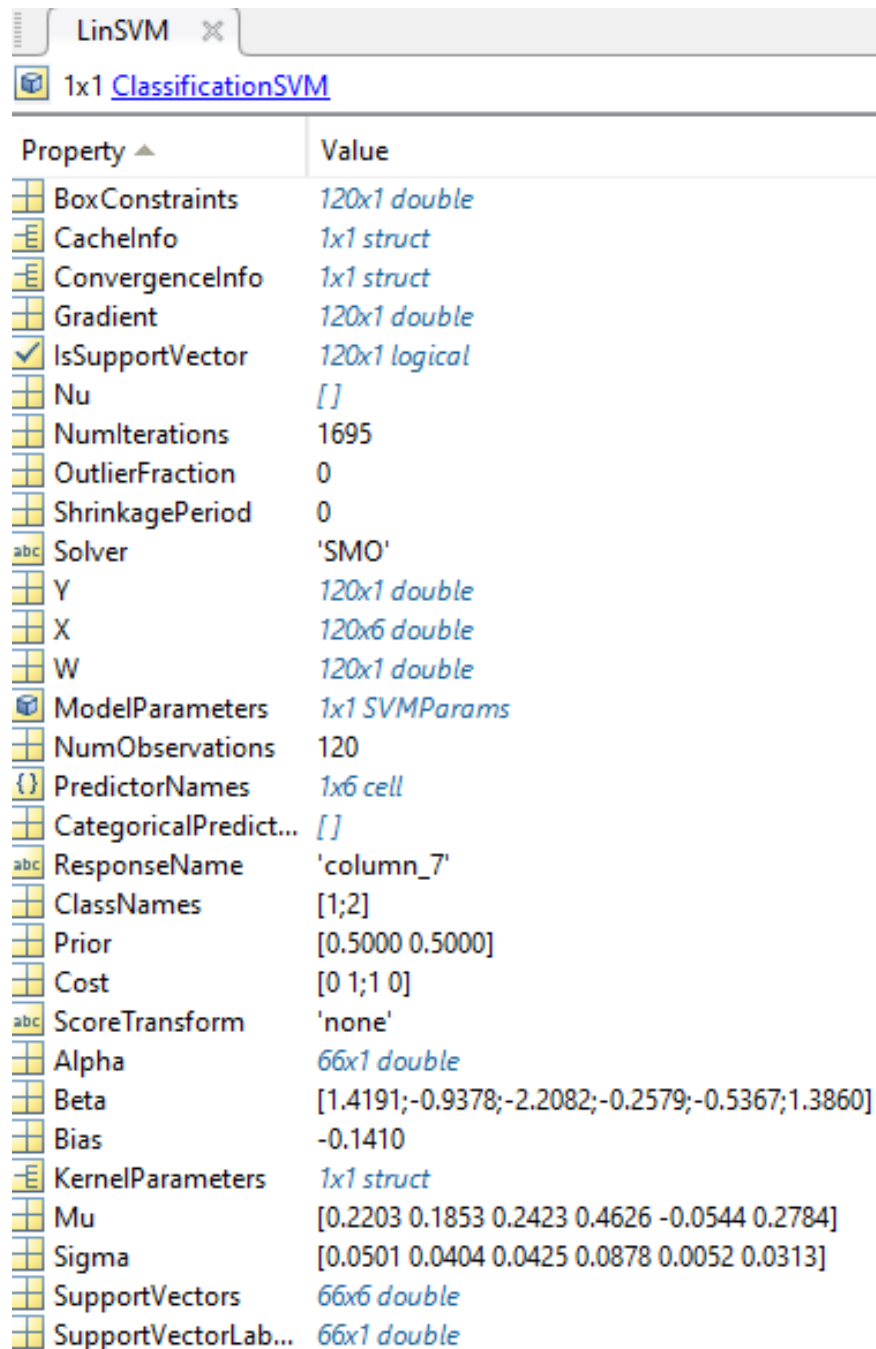
Conjunto	Número de granos	Morados	Blancos
Entrenamiento	120	60	60
Validación	60	30	30

Fuente: Elaboración propia.

Utilizando los espectros de los granos de cacao y sus respectivos índices espectrales, se crearon, entrenaron y validaron distintos modelos de clasificación.

De los distintos modelos de clasificación se escogió el de mejor rendimiento resultando el modelo Linear SVM con un porcentaje promedio de acierto de 86.8%. En la Figura 74, se especifican los parámetros más importantes del modelo de clasificación Lineal SVM, el detalle de cada uno de los parámetros se encontrarán en los Anexos.





Property ▲	Value
BoxConstraints	120x1 double
CacheInfo	1x1 struct
ConvergenceInfo	1x1 struct
Gradient	120x1 double
IsSupportVector	120x1 logical
Nu	[]
NumIterations	1695
OutlierFraction	0
ShrinkagePeriod	0
Solver	'SMO'
Y	120x1 double
X	120x6 double
W	120x1 double
ModelParameters	1x1 SVMParams
NumObservations	120
PredictorNames	1x6 cell
CategoricalPredict...	[]
ResponseName	'column_7'
ClassNames	[1;2]
Prior	[0.5000 0.5000]
Cost	[0 1;1 0]
ScoreTransform	'none'
Alpha	66x1 double
Beta	[1.4191;-0.9378;-2.2082;-0.2579;-0.5367;1.3860]
Bias	-0.1410
KernelParameters	1x1 struct
Mu	[0.2203 0.1853 0.2423 0.4626 -0.0544 0.2784]
Sigma	[0.0501 0.0404 0.0425 0.0878 0.0052 0.0313]
SupportVectors	66x6 double
SupportVectorLab...	66x1 double

**Figura 74.** Parámetros del modelo de clasificación Linear SVM.

Fuente: Elaboración propia.

## 5.2 Aplicación

Los resultados obtenidos usando el clasificador entrenado Linear SVM se compararon con los obtenidos mediante la clasificación manual obteniendo un porcentaje promedio de acierto de 85.7%. En la Tabla 8 se presentan los resultados de la primera prueba de validación. En el apartado de Anexos se encontrarán los resultados de todas las pruebas de validación de modelo de clasificación Lineal SVM. El valor 1 representa granos morados y el valor 2 representa granos blancos.

**Tabla 8.** Primera prueba de validación de modelo de clasificación Linear SVM.

Base		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m276	0.282650659	0.251620282	0.23929518	0.521945839	-0.046721256	0.273874609	1	1
2	m277	0.161144289	0.141673408	0.180214756	0.341359045	-0.040389498	0.224213219	1	1
3	m278	0.117367906	0.098561082	0.206469913	0.323837819	-0.044723139	0.242798314	1	1
4	m279	0.151369692	0.116647794	0.208701212	0.360070904	-0.039885306	0.230474095	1	1
5	m280	0.132636427	0.118538541	0.184741895	0.317378322	-0.04281571	0.232955025	1	1
6	m281	0.267487786	0.235596694	0.243344092	0.510831878	-0.04936803	0.280074791	1	1
7	m282	0.131434628	0.119698804	0.173701173	0.3051358	-0.040462918	0.227636411	1	1
8	m283	0.290953322	0.258400082	0.257354973	0.548308294	-0.049172875	0.279495534	1	1
9	m284	0.320425898	0.282769345	0.275512541	0.595938439	-0.053358947	0.296831137	1	1
10	m285	0.312875704	0.266543091	0.286592112	0.599467815	-0.053363676	0.299100094	1	1
11	m286	0.427411175	0.366300336	0.302503179	0.729914354	-0.053616011	0.307456939	1	1
12	m287	0.44254118	0.382442513	0.305865202	0.748406383	-0.05309737	0.305615174	1	1
13	m288	0.139774394	0.102460496	0.216512029	0.356286423	-0.039734446	0.22634229	1	1
14	m289	0.193202831	0.169521262	0.211411075	0.404613906	-0.04343436	0.250278221	1	1
15	m290	0.201105161	0.173052407	0.242595401	0.443700562	-0.047101648	0.268351082	1	1
16	m291	0.13465485	0.106851421	0.205169723	0.339824573	-0.04337527	0.235954879	1	1
17	m292	0.304122309	0.243538071	0.278524842	0.582647151	-0.051788131	0.29150829	1	1
18	m293	0.23788449	0.204369707	0.257982112	0.495866601	-0.050700667	0.283272618	1	1
19	m294	0.227843454	0.20325578	0.227589856	0.45543331	-0.047236812	0.267743199	1	1
20	m295	0.175860558	0.154254316	0.2109921	0.386852658	-0.04381083	0.24668485	1	1
21	m296	0.192937043	0.173026877	0.214267679	0.407204721	-0.04368511	0.246749317	1	1
22	m297	0.272882221	0.249594175	0.224606284	0.497488505	-0.048843327	0.270624187	1	1
23	m299	0.247315468	0.214766108	0.263603583	0.510919051	-0.051577219	0.285978152	1	1
24	m300	0.225665317	0.194140756	0.275328916	0.500994232	-0.050542644	0.288783297	1	1
25	m301	0.262182894	0.231811343	0.240607984	0.502790878	-0.047130348	0.269663566	1	1
26	m302	0.181355668	0.162439991	0.209233626	0.390589294	-0.044461518	0.250719688	1	1
27	m303	0.191772713	0.171921228	0.19544347	0.387216182	-0.04397001	0.244113724	1	1
28	m304	0.198392625	0.162832741	0.243436754	0.441829379	-0.048122661	0.277020103	1	1
29	m305	0.112285398	0.09827929	0.164405944	0.276691343	-0.037183451	0.204770255	1	1
30	m306	0.165284221	0.128085651	0.235125299	0.40040952	-0.045407553	0.258562078	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1
32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.229071133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2

Fuente: Elaboración propia.

**Tabla 8.** Primera prueba de validación de modelo de clasificación Linear SVM  
(continuación).

Base		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1
39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2
49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2
56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	54
								%	90

Fuente: Elaboración propia.



## **Capítulo 6**

### **Conclusiones**

En este capítulo se resumen las principales conclusiones y líneas futuras de esta tesis.

1. El desarrollo de sistemas de imágenes hiperespectrales para el análisis de las características o propiedades de productos agrícolas permite descubrir mayor información de forma no destructiva como diferentes parámetros físicos y componentes químicos definidos espacialmente en los productos.
2. Para el uso correcto de la información obtenida de imágenes hiperespectrales, es importante realizar un procesamiento adecuado de la imagen. La mayor parte de las técnicas y métodos de procesamiento y análisis de imágenes digitales (RGB) pueden utilizarse para el procesamiento y análisis de imágenes hiperespectrales.
3. Existen distintas herramientas de software para el procesamiento y análisis de imágenes hiperespectrales como ENVI y MATLAB, sin embargo, se puede desarrollar un software de procesamiento de imágenes hiperespectrales según la aplicación que se desee.
4. Los principales problemas presentes en el análisis de imágenes hiperespectrales es la baja velocidad de cálculo y la redundancia de información. Por ello, en algunas aplicaciones, sistemas de imágenes hiperespectrales se usan como referencia para desarrollar sistemas de imágenes multiespectrales utilizando 3-4 bandas con un costo relativamente bajo y alta velocidad analítica. Las bandas espectrales utilizadas en los índices hiperespectrales permitirían diseñar un sistema multiespectral.
5. Los sistemas de imágenes multiespectrales pueden ser utilizados en la clasificación en línea pero las desventajas más notables del uso de sistemas multiespectrales es la posible pérdida de información importante y la limitación del alcance potencial de la aplicación final.

6. Un problema importante en los sistemas hiperespectrales es que, en algunos casos, los resultados dependen de las condiciones de laboratorio (iluminación, calibración, etc.) o de los métodos de análisis utilizados y no se relacionan con las propiedades físico-químicas.
7. El resultado de esta tesis es un sistema para la clasificación de granos de cacao intactos según su color interno, utilizando técnicas de procesamiento de imágenes hiperespectrales y un clasificador Linear SVM, con un porcentaje de acierto de 85.7% en un total de 300 imágenes evaluadas.
8. La iluminación es muy importante en los sistemas de visión hiperespectral, su disposición e intensidad influyen en el procesamiento de la imagen. Una mejora del sistema presentado es colocar una caja oscura que contenga la cámara hiperespectral para mantener una iluminación más uniforme.
9. Las investigaciones futuras basadas en imágenes hiperespectrales deben tener en cuenta utilizar cámaras de alta sensibilidad, sistemas de mayor resolución y métodos eficientes de procesamiento de datos. Y, en el análisis de productos agrícolas, la información resultante sería más completa y precisa si se utilizan simultáneamente diferentes técnicas no destructivas.
10. Durante el proceso de fermentación, el color interno de los granos de cacao varía gradualmente. Se puede monitorear y relacionar el cambio de color y la variación de temperatura en la fermentación, y así determinar si las condiciones de fermentación son las adecuadas: condiciones ambientales, técnicas de fermentación, tiempo de fermentación, etc.

## Referencias

- Aceituno, V. M. (2010). *Propiedades de colorantes naturales secados con técnicas alternativas a nivel laboratorio como alternativa al FD&C rojo No. 40 en alimentos* (Tesis de pregrado). Universidad de San Carlos de Guatemala, Guatemala.
- Aculey, P. C., Snitkjaer, P., Owusu, M., Bassompierre, M., Takrama, J., Nørgaard, L., Petersen, M. A., & Nielsen, D. S. (2010). Ghanaian cocoa bean fermentation characterized by spectroscopic and chromatographic methods and chemometrics. *Journal of food science*, 75(6), S300-S307.
- Afoakwa, E.O. (2010). *Chocolate Science and Technology*. John Wiley & Sons.
- Afoakwa, E.O., Quao, J., Takrama, J., Budu, A. S., y Saalia, F. K. (2012). Influence of pulp-preconditioning and fermentation on fermentative quality and appearance of Ghanaian cocoa (*Theobroma cacao*) beans. *International Food Research Journal* 19(1), 127-133.
- Afoakwa, E. O., Kongor, J. E., Takrama, J. F., Budu, A. S., & Mensah-Brown, H. (2013). Effects of pulp preconditioning on total polyphenols, o-diphenols and anthocyanin concentrations during fermentation and drying of cocoa (*Theobroma cacao*) beans. *Journal of Food Science and Engineering*, 3(5), 235-245.
- Afoakwa, E. O. (2014). *Cocoa Production and Processing Technology*. CRC Press.
- Aguilera, M. (2009). *Caracterización y estabilidad de las antocianinas de higo Ficus carica variedad Misión, cultivado en ciudad Lerdo Durango, México* (Tesis doctoral). Universidad Autónoma de Nuevo León, México.
- Alas, C. A., & Morales, A. D. S. (2015). *Estandarización del proceso de fermentación de la mezcla de semillas de tres accesiones de Theobroma cacao L. (Cacao) de cultivar San José del Real de la Carrera ubicada en el Departamento de Usulután* (Tesis de licenciatura). Universidad de El Salvador, San Salvador, El Salvador.
- Amores, F., Palacios, A., Jiménez, J., Zhang, D. (2009). Entorno ambiental, genética, atributos de calidad y singularización del cacao en el nor oriente de la provincia de Esmeraldas. Instituto Nacional Autónomo de Investigaciones Agropecuarias. Estación Experimental Tropical Pichilingue. Boletín técnico N° 135.
- Aroni, J. (2013). *Evaluación de la estabilidad de antocianinas presentes en los frutos de Hesperomeles escalloniifolia Schlttl (Capachu), Berberis cummutata Eichler (Huancachu), Berberis humbertiana J. F. Macbr (Cheqche) y Vaccinium floribundum Kunth (Alaybilí) frente al pH y temperatura* (Tesis de pregrado). Universidad Nacional José María Arguedas. Andahuaylas, Perú.

- ASPROBO BUENOS AIRES (2011). Manual de Procedimientos de Cosecha y Acopio de Cacao, en el distrito de Buenos Aires-Morropón. Aplicación de la Norma Técnica Peruana NTP 208.040:2008. Buenas Prácticas para la Cosecha y Beneficio de Cacao. Proyecto: PIPEA 107-2011.
- ASPROBO BUENOS AIRES (2011). Procedimientos validados para las buenas prácticas de beneficio de cacao. Aplicación de la Norma Técnica Peruana NTP 208.040:2008. Buenas Prácticas para la Cosecha y Beneficio de Cacao. NTP 1114:2006. Granos de Cacao. Prueba de corte. Proyecto: PIPEA 107-2011.
- Birth, G. S. (1976). How light interacts with foods. En J. J. Gafney (Ed.), *Quality detection in foods* (pp. 6-11). St Joseph, MI: ASAE.
- Bureau, S. (2009). The use of non-destructive methods to analyse fruit quality. *Fresh Produce* 3(Special Issue 1), 23-34.
- Chivkunova, O. B., Solovchenko, A. E., Sokolova, S. G., Merzlyak, M. N., Reshetnikova, I. V., & Gitelson, A. A. (2001). Reflectance spectral features and detection of superficial scald-induced browning in storing apple fruit. *J. Russian Phytopathol. Soc.*, 2, 73-77.
- Choe, E., van der Meer, F., van Ruitenbeek, F., van der Werff, H., de Smeth, B., & Kim, K. W. (2008). Mapping of heavy metal pollution in stream sediments using combined geochemistry, field spectroscopy, and hyperspectral remote sensing: A case study of the Rodalquilar mining area, SE Spain. *Remote Sensing of Environment*, 112(7), 3222-3233.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- ElMasry, G., & Sun, D. W. (2010). Principles of hyperspectral imaging technology. En D. W. Sun (Ed.), *Hyperspectral imaging for food quality analysis and control*, (pp. 3-43). Elsevier.
- Fernandes, A. M., Franco, C., Mendes-Ferreira, A., Mendes-Faia, A., da Costa, P. L., & Melo-Pinto, P. (2015). Brix, pH and anthocyanin content determination in whole Port wine grape berries by hyperspectral imaging and neural networks. *Computers and Electronics in Agriculture*, 115, 88-96.
- Fowler, M. S. (2009). Cocoa beans: From tree to factory. En S. T. Beckett (Ed.), *Industrial chocolate manufacture and use*, (pp. 10-47). John Wiley & Sons.
- Fuentes, W. (2005). *Extracción, cuantificación y estabilidad de colorantes naturales presentes en los frutos de Prunus capulí Cav. (Cereza), Rubus urticaefolius Poir. (Mora) y Sambucus canadensis L. (Sauco) como alternativas naturales de consumo de los colorantes artificiales rojo No. 40, rojo No. 3 y rojo No. 2, en bebidas en el rango de pH: 3, 4 y 5* (Tesis de pregrado). Universidad de San Carlos de Guatemala, Guatemala.



- Gamon, J. A., Peñuelas, J., & Field, C. B. (1992). A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of environment*, 41(1), 35-44.
- García, L. F. (2010). Catálogo de cultivares de cacao del Perú. Ministerio de Agricultura y Riego-DEVIDA-Perú Progreso para Todos.
- García-Allende, P. B., Conde, O. M., & López-Higuera, J. M. (2011). Hyperspectral imaging for raw material sorting and processed product quality control. En O. Ivanov (Ed.), *Applications and Experiences of Quality Control*, (pp. 663-686). InTech.
- Geyer, M., Herold, B., Zude, M., & Truppel, I. (2007). Non-destructive evaluation of apple fruit maturity on the tree. *Vegetable Crops Research Bulletin*, 66, 161-169.
- Gitelson, A. A., Merzlyak, M. N., & Chivkunova, O. B. (2001). Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and photobiology*, 74(1), 38-45.
- Gitelson, A. A., Zur, Y., Chivkunova, O. B., & Merzlyak, M. N. (2002a). Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. *Photochemistry and photobiology*, 75(3), 272-281.
- Goetz, A. F. H., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging spectrometry for earth remote sensing. *Science*, 228(4704), 1147-1153.
- Gómez, J. (2010). *Detección automática de podredumbres en cítricos mediante procesado avanzado de imágenes hiperespectrales* (Tesis doctoral). Universidad de Valencia, Valencia.
- Gómez, R., García, R., Tong, F., & González, C. (2014). Paquete Tecnológico del Cultivo del Cacao Fino de Aroma. UNODC-DEVIDA-Perú Progreso para Todos.
- González, R. C., & Woods, R. E. (2002). *Digital Image Processing* (2ª Ed.) New Jersey: Prentice Hall, Inc.
- Gutiérrez, B. E. (2011). *Estudio agromorfológico y fisicoquímico de los ecotipos de cacao cultivados en los municipios de Izalco y Nahulingo, en el Departamento de Sonsonate en El Salvador* (Tesis de pregrado). Universidad Dr. José Matías Delgado, Antiguo Cuscatlán.
- He, J., & Giusti, M. M. (2010). Anthocyanins: natural colorants with health-promoting properties. *Annual review of food science and technology*, 1, 163-187.
- Herold, B., Truppel, I., Zude, M., & Geyer, M. (2005). Spectral measurements on “Elstar” apples during fruit development on the tree. *Biosystems Engineering*, 91(2), 173-182.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.

- Infante, R., Contador, L., Rubio, P., Mesa, K., & Meneses, C. (2011). Non-destructive monitoring of flesh softening in the black-skinned Japanese plums “Angelino” and “Autumn beaut” on-tree and postharvest. *Postharvest Biology and Technology*, 61(1), 35-40.
- Jackson, R. D., & Huete, A. R. (1991). Interpreting vegetation indices. *Preventive veterinary medicine*, 11(3-4), 185-200.
- Jiang, L., Zhu, B., & Tao, Y. (2010). Hyperspectral image classification methods. En D. W. Sun (Ed.), *Hyperspectral imaging for food quality analysis and control*, (pp. 79-98). Elsevier.
- Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663-666.
- Lleó, L., Roger, J. M., Herrero-Langreo, A., Diezma-Iglesias, B., & Barreiro, P. (2011). Comparison of multispectral indexes extracted from hyperspectral images for the assessment of fruit ripening. *Journal of Food Engineering*, 104(4), 612-620.
- Lorente, D., Aleixos, N., Gómez-Sanchis, J., Cubero, S., García-Navarrete, O. L., & Blasco, J. (2012). Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. *Food and Bioprocess Technology*, 5(4), 1121-1142.
- Lu, G., & Fei, B. (2014). Medical hyperspectral imaging: a review. *Journal of biomedical optics*, 19(1), 010901.
- Merzlyak, M. N., Gitelson, A. A., Chivkunova, O. B., & Rakitin, V. Y. (1999). Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia plantarum*, 106(1), 135-141.
- Merzlyak, M. N., Solovchenko, A. E., & Gitelson, A. A. (2003a). Reflectance spectral features and non-destructive estimation of chlorophyll, carotenoid and anthocyanin content in apple fruit. *Postharvest Biology and Technology*, 27(2), 197-211.
- Merzlyak, M. N., Gitelson, A. A., Chivkunova, O. B., Solovchenko, A. E., & Pogosyan, S. I. (2003b). Application of reflectance spectroscopy for analysis of higher plant pigments. *Russian journal of plant physiology*, 50(5), 704-710.
- Merzlyak, M. N., Solovchenko, A. E., Smagin, A. I., & Gitelson, A. A. (2005). Apple flavonols during fruit adaptation to solar radiation: spectral features and technique for non-destructive assessment. *Journal of plant physiology*, 162(2), 151-160.
- Moscol, M., Espinoza, E., Mendoza, L., Rojas, J. C., & Salvador, N. (2012). Manual Manejo Técnico del Cultivo de Cacao Blanco de Piura. Ministerio de Agricultura.
- Munawar, A. A. (2014). *Multivariate analysis and artificial neural network approaches of near infrared spectroscopic data for non-destructive quality attributes prediction of Mango (Mangifera indica L.)* (Tesis doctoral). Georg-August-Universität, Göttingen, Alemania.

- Ngadi, M. O., & Liu, L. (2010). Hyperspectral Image Processing Techniques. En D. W. Sun (Ed.), *Hyperspectral imaging for food quality analysis and control*, (pp. 99-127). Elsevier.
- Pettipher, G. M. (1986). An improved method for the extraction and quantitation of anthocyanins in cocoa beans and its use as an index of the degree of fermentation. *Journal of the Science of Food and Agriculture*, 37(3), 289-296.
- Pu, Y. Y., Feng, Y. Z., & 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.
- Qin, J., & Lu, R. (2008). Measurement of the optical properties of fruits and vegetables using spatially resolved hyperspectral diffuse reflectance imaging technique. *Postharvest Biology and Technology*, 49(3), 355-365.
- Qin, J. (2010). Hyperspectral imaging instruments. En D. W. Sun (Ed.), *Hyperspectral imaging for food quality analysis and control*, (pp. 129-172). Elsevier.
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., & Harlan, J. C. (1974). Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation.
- Ruiz, J., Soto, J., Ipanaqué, W., & Chinguel, C. (2016). New hyperspectral index for determining the state of fermentation in the non-destructive analysis for organic cocoa violet. En *Automática (ICA-ACCA), IEEE International Conference on*, (pp. 1-6). IEEE.
- Rutkowski, K. P., Michalczuk, B., & Konopacki, P. (2008). Nondestructive determination of "Golden Delicious" apple quality and harvest maturity. *J. Fruit Ornament. Plant Res*, 16, 39-52.
- Silva, C. S., Pimentel, M. F., Honorato, R. S., Pasquini, C., Prats-Montalbán, J. M., & Ferrer, A. (2014). Near infrared hyperspectral imaging for forensic analysis of document forgery. *Analyst*, 139(20), 5176-5184.
- Sunoj, S., Igathinathane, C., & Visvanathan, R. (2016). Nondestructive determination of cocoa bean quality using FT-NIR spectroscopy. *Computers and Electronics in Agriculture*, 124, 234-242.
- Tao, T. (2011). *Multispectral Method for Apple Defect Detection using Hyperspectral Imaging System* (Tesis de maestría). Universidad de Maryland, EE. UU.
- Terán, M. F., & Viteri, L. A. (2005). *Procesamiento de imágenes satelitales para determinación de cambios de cobertura vegetal y deforestación utilizando MATLAB* (Tesis de pregrado). Escuela Politécnica nacional, Quito.

- Teye, E., Huang, X., Dai, H., & Chen, Q. (2013). Rapid differentiation of Ghana cocoa beans by FT-NIR spectroscopy coupled with multivariate classification. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 114, 183-189.
- Teye, E., Huang, X. Y., Lei, W., & Dai, H. (2014). Feasibility study on the use of Fourier transform near-infrared spectroscopy together with chemometrics to discriminate and quantify adulteration in cocoa beans. *Food Research International*, 55, 288-293.
- Teye, E., Huang, X., Sam-Amoah, L. K., Takrama, J., Boison, D., Botchway, F., & Kumi, F. (2015). Estimating cocoa bean parameters by FT-NIRS and chemometrics analysis. *Food chemistry*, 176, 403-410.
- Travers, S. (2013). *Dry matter and fruit quality: manipulation in the field and evaluation with NIR spectroscopy* (Tesis doctoral). Universidad de Aarhus. Aarhus, Denmark.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
- Viera, G. I. (2017). *Procesamiento de Imágenes usando openCV aplicado en Raspberry Pi para la Clasificación del Cacao* (Tesis de pregrado). Universidad de Piura, Piura, Perú.
- Von, E. A. (2012). *Uso de imágenes satelitales multiespectrales e índices de vegetación, como herramientas para estudiar el desarrollo fenológico y crecimiento del cerezo (Prunus avium L.) en tres localidades de la provincia de Curicó, región del Maule-Chile* (Tesis de maestría). Universidad de Talca, Talca, Chile.
- Wiegand, C. L., Richardson, A. J., Escobar, D. E., & Gerbermann, A. H. (1991). Vegetation indices in crop assessments. *Remote Sensing of Environment*, 35(2-3), 105-119.
- Wollgast, J., & Anklam, E. (2000). Review on polyphenols in Theobroma cacao: changes in composition during the manufacture of chocolate and methodology for identification and quantification. *Food Research International*, 33(6), 423-447.
- Wu, D., & Sun, D. W. (2013). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review—Part I: Fundamentals. *Innovative Food Science & Emerging Technologies*, 19, 1-14.
- Yang, C., Lee, W. S., & Williamson, J. G. (2012). Classification of blueberry fruit and leaves based on spectral signatures. *Biosystems engineering*, 113(4), 351-362.
- Yang, C. (2013). *Spectral analysis and multispectral/hyperspectral imaging to detect blueberry fruit maturity stages for early blueberry yield estimation* (Tesis doctoral). Universidad de Florida, Florida, EE. UU.
- Yao, H., & Lewis, D. (2010). Spectral preprocessing and calibration techniques. En D. W. Sun (Ed.), *Hyperspectral imaging for food quality analysis and control*, (pp. 45-78). Elsevier.

- Zanella, A., Vanoli, M., Rizzolo, A., Grassi, M., Eccher Zerbini, P., Cubeddu, R., Torricelli, A., & Spinelli, L. (2012). Correlating optical maturity indices and firmness in stored “Braeburn” and “Cripps Pink” apples. En *VII International Postharvest Symposium 1012*, 1173-1180.
- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, 62, 326-343.
- Ziosi, V., Noferini, M., Fiori, G., Tadiello, A., Trainotti, L., Casadoro, G., & Costa, G. (2008). A new index based on vis spectroscopy to characterize the progression of ripening in peach fruit. *Postharvest biology and technology*, 49(3), 319-329.
- Zude, M. (2003). Comparison of indices and multivariate models to non-destructively predict the fruit chlorophyll by means of visible spectrometry in apple fruit. *Analytica Chimica Acta*, 481(1), 119-126.
- Zulfahrizal, Meilina, H., & Munawar, A. A. (2016). The Use of Spectral Imaging Technology Combined with Support Vector Machine as A Fast and Novel Tools for Fat Content Determination of Intact Cocoa Beans. En *International Conference on Technology, Innovation, and Society (ICTIS)*, 98-102.



## **ANEXOS**





## Anexo A

### A-1: Código fuente para construcción de base de datos

Archivo: “Granocentro.m”

```
clc; clear all;

for M =1:120
clearvars -except vector M Ind Rf

band = importdata('bandas.txt');
band_inter = importdata('bandas_inter.txt');

H = multibandread(['D:\gaby\Muestras hiper\kk\m',num2str(M),'.bil'],...
                  [349,640,240],'uint16',0,'bil','ieee-le');

% H = multibandread(['D:\gaby\Muestras hiper\kk\m1.bil'],...
%                  [349,640,240],'uint16',0,'bil','ieee-le');

H = (H(end:-1:1, :, :)/4096);
blue = H(:, :, 33);

%% Recorte de la imagen

um = graythresh(blue);
imbw = im2bw(blue,um);
imbw = imfill(~imbw,'holes');
Reg = regionprops(imbw);

if ~isempty(Reg)
    area = 0;
    indice = 1;
    for i = 1:length(Reg)
        if area < Reg(i).Area
            area = Reg(i).Area;
            indice = i;
        end
    end

    xnew = round(Reg(indice).BoundingBox(1));
    ynew = round(Reg(indice).BoundingBox(2));
    width = round(Reg(indice).BoundingBox(3));
    heigh = round(Reg(indice).BoundingBox(4));

    He = H(ynew : ynew + heigh, xnew : xnew + width, :);
    nir = He(:, :, 225);
    red = He(:, :, 119);
    green = He(:, :, 76);
    bluenew = He(:, :, 33);

    width = width + 1;
    heigh = heigh + 1;

    x = zeros(heigh*width,240);
```

```

for i = 1:240
    x(:,i) = reshape(He(:,:,i)',heigh*width,1);
end

```

```
%% Procesamiento de imagen
```

```

[coeff,score,latent] = pca(x);
impca1 = reshape(score(:,1),width,heigh)';
img = ~im2bw(impca1);
img = imfill(img,'holes');
se = strel('square',5);
img = imerode(img,se);
se = strel('square',30);
imgerode = imerode(img,se);

R = regionprops(img,'all');
imcentro = zeros(heigh,width);

x0 = zeros(1,629);
y0 = zeros(1,629);
if (~isempty(R))
    for k = 1:length(R) % área seleccionada
        c = 0;
        for i = 0:0.01:2*pi
            c = c + 1;
            x0(c)=R(k).Centroid(1)+R(k).MinorAxisLength*(0.4*1.0)*cos(i);
            y0(c)=R(k).Centroid(2)+R(k).MinorAxisLength*(0.4*1.0)*sin(i);
        end
        x0(end) = x0(1);
        y0(end) = y0(1);
        imcentro = imcentro + poly2mask(x0,y0,heigh,width);
    end
end
imcentro = imcentro & imgerode;
completo = bwperim(img);
centro = bwperim(imcentro);
se = strel('square',2);
centro = imdilate(centro,se);

Rnew = regionprops(imcentro);
Hn = He; %desarrollo espectro
Area = 0;
for i = 1:length(Rnew)
    Area = Area + Rnew(i).Area;
end
spectro = zeros(1,240);
for i = 1:240
    Hn(:,:,i) = He(:,:,i).*double(imcentro);
    val = sum(sum(Hn(:,:,i)))/(Area);
    spectro(i) = val;
end
t1 = nir + centro;
t2 = red + centro;
t3 = bluenew + centro;
im = im2uint16(cat(3,t1,t2,t3));

```

```

%% Graficos

figure(1)
plot(band,spectro,'b')% plot(band,spectro,'r')
title('Espectro promedio')
set(gca,'XTick',[500,600,700,800])
set(gca,'YTick',[0.00,0.50,1.00])
axis([393 893 0.0 1.0])
hold on
grid on
figure(2*M)
imshow(im)

%% Indices y reflectancias

ref_I = interp1 (band, spectro, band_inter, 'line');
Ind(M,1) = (1./ref_I(7) - 1./ref_I(10)); % ARI1=(1./R550 - 1./R700);
Ind(M,2)=ref_I(12).*(1./ref_I(7)-1./ref_I(10))
% AR12 = R800*(1./R550-1./R700);
Ind(M,3) = (1./ref_I(4) - 1./ref_I(7)); % CRI1=(1./R510 - 1./R550);
Ind(M,4) = (1./ref_I(4) - 1./ref_I(10)); % CRI2=(1./R510 - 1./R700);
Ind(M,5)=(ref_I(6)-ref_I(8))/(ref_I(6)+ref_I(8));
% PRI = (R531-R570)/(R531+R570);
Ind(M,6) = (ref_I(9) - ref_I(3))/(ref_I(11));
% PSRI = (R680 - R500)/(R750);

Rf(M,1) = ref_I(1); %R445
Rf(M,2) = ref_I(3); %R500
Rf(M,3) = ref_I(4); %R510
Rf(M,4) = ref_I(6); %R531
Rf(M,5) = ref_I(7); %R550
Rf(M,6) = ref_I(8); %R570
Rf(M,7) = ref_I(9); %R680
Rf(M,8) = ref_I(10); %R700
Rf(M,9) = ref_I(11); %R750
Rf(M,10) = ref_I(12); %R800

end

end

```

## A-2: Código fuente de interfaz

Archivo: “HYC.m”

```
function varargout = HYC(varargin)
% HYC MATLAB code for HYC.fig
%   HYC, by itself, creates a new HYC or raises the existing
%   singleton*.
%
%   H = HYC returns the handle to a new HYC or the handle to
%   the existing singleton*.
%
%   HYC('CALLBACK',hObject,eventData,handles,...) calls the local
%   function named CALLBACK in HYC.M with the given input arguments.
%
%   HYC('Property','Value',...) creates a new HYC or raises the
%   existing singleton*. Starting from the left, property value pairs
are
%   applied to the GUI before HYC_OpeningFcn gets called. An
%   unrecognized property name or invalid value makes property
application
%   stop. All inputs are passed to HYC_OpeningFcn via varargin.
%
%   *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only
one
%   instance to run (singleton)".
%
% See also: GUIDE, GUIDATA, GUIHANDLES

% Edit the above text to modify the response to help HYC

% Last Modified by GUIDE v2.5 29-Jan-2018 10:53:57

% Begin initialization code - DO NOT EDIT
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',   gui_Singleton, ...
                  'gui_OpeningFcn', @HYC_OpeningFcn, ...
                  'gui_OutputFcn',  @HYC_OutputFcn, ...
                  'gui_LayoutFcn',   [] , ...
                  'gui_Callback',    []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
% End initialization code - DO NOT EDIT

% --- Executes just before HYC is made visible.
function HYC_OpeningFcn(hObject, eventdata, handles, varargin)
% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
```

```

% handles      structure with handles and user data (see GUIDATA)
% varargin     command line arguments to HYC (see VARARGIN)

global band band_inter
evalin( 'base', 'clearvars *' )
set(handles.Process_Pushbutton,'Enable','off');
set(handles.Clear_Pushbutton,'Enable','off');

band = importdata('bandas.txt');
band_inter = importdata('bandas_inter.txt');

datos = get(handles.Ind_table,'data');
datos(:, :) = [];
set(handles.Ind_table,'data', datos);

% Choose default command line output for HYC
handles.output = hObject;

% Update handles structure
guidata(hObject, handles);

% UIWAIT makes HYC wait for user response (see UIRESUME)
% uiwait(handles.figure1);

% --- Outputs from this function are returned to the command line.
function varargout = HYC_OutputFcn(hObject, eventdata, handles)
% varargout    cell array for returning output args (see VARARGOUT);
% hObject     handle to figure
% eventdata   reserved - to be defined in a future version of MATLAB
% handles     structure with handles and user data (see GUIDATA)

% Get default command line output from handles structure
varargout{1} = handles.output;

% --- Executes on button press in Import_Pushbutton.
function Import_Pushbutton_Callback(hObject, eventdata, handles)
% hObject     handle to Import_Pushbutton (see GCBO)
% eventdata   reserved - to be defined in a future version of MATLAB
% handles     structure with handles and user data (see GUIDATA)

global number FileName PathName

[FileName,PathName]=uigetfile('*.bil', 'Select
files','MultiSelect','on');
File = char(FileName);
number = size(File,1);
if number ~= 1
    File = char(FileName(1,number));
end

H = multibandread([PathName,File],[349,640,240],'uint16',0,'bil','ieee-
le');
H = (H(end:-1:1,:,:)/4096);
nir0   = H(:,:,225);
red0   = H(:,:,119);
green0 = H(:,:, 76);
blue0  = H(:,:, 33);

```

```

img0 = im2uint16(cat(3,nir0,red0,blue0));

axes(handles.multimage);
cla
imshow(img0);
set(handles.Process_Pushbutton,'Enable','on');
set(handles.Clear_Pushbutton,'Enable','on');

% --- Executes on button press in Clear_Pushbutton.
function Clear_Pushbutton_Callback(hObject, eventdata, handles)
% hObject      handle to Clear_Pushbutton (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

datos = get(handles.Ind_table,'data');
datos(:, :) = [];
set(handles.Ind_table,'data', datos);

set(handles.Process_Pushbutton,'Enable','off');

cla(handles.multimage, 'reset')
set(handles.multimage,'xtick',[],'ytick',[],'Xcolor','w','Ycolor','w')
cla(handles.center, 'reset')
set(handles.center,'xtick',[],'ytick',[],'Xcolor','w','Ycolor','w')
cla(handles.spectro, 'reset')
set(handles.spectro,'xtick',[],'ytick',[],'Xcolor','w','Ycolor','w')

evalin( 'base', 'clearvars *' )

% --- Executes on button press in Process_Pushbutton.
function Process_Pushbutton_Callback(hObject, eventdata, handles)
% hObject      handle to Process_Pushbutton (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

global band band_inter number FileName PathName

for n = 1:number
    File = char(FileName(1,n));
    if number == 1
        File = char(FileName);
    end
    H =
multibandread([PathName,File],[349,640,240],'uint16',0,'bil','ieee-le');
    H = (H(end:-1:1, :, :)/4096);
    blue0 = H(:, :, 33);

    um = graythresh(blue0);
    imbw = im2bw(blue0,um);
    imbw = imfill(~imbw,'holes');
    Reg = regionprops(imbw);

    if ~isempty(Reg)
        area = 0;
        indice = 1;
        for i = 1:length(Reg)
            if area < Reg(i).Area
                area = Reg(i).Area;

```

```

        indice = i;
    end
end

xnew = round(Reg(indice).BoundingBox(1));
ynew = round(Reg(indice).BoundingBox(2));
width = round(Reg(indice).BoundingBox(3));
heigh = round(Reg(indice).BoundingBox(4));

He = H(ynew : ynew + heigh, xnew : xnew + width,:);
nir = He(:, :, 225);
red = He(:, :, 119);
green = He(:, :, 76);
blue = He(:, :, 33);

width = width + 1;
heigh = heigh + 1;

x = zeros(heigh*width, 240);
for i = 1:240
    x(:, i) = reshape(He(:, :, i)', heigh*width, 1);
end
[coeff, score, latent] = pca(x);
impcal = reshape(score(:, 1), width, heigh)';
img = ~im2bw(impcal);
img = imfill(img, 'holes');
se = strel('square', 5);
img = imerode(img, se);
se = strel('square', 30);
imgerode = imerode(img, se);

R = regionprops(img, 'all');
imcentro = zeros(heigh, width);
x0 = zeros(1, 629);
y0 = zeros(1, 629);

if (~isempty(R))
    for k = 1:length(R) %para formr un circulo del grnao
        c = 0;
        for i = 0:0.01:2*pi
            c = c + 1;
            x0(c) = R(k).Centroid(1) +
R(k).MinorAxisLength*(0.4*1.0)*cos(i);
            y0(c) = R(k).Centroid(2) +
R(k).MinorAxisLength*(0.4*1.0)*sin(i);
        end
        x0(end) = x0(1);
        y0(end) = y0(1);
        imcentro = imcentro + poly2mask(x0, y0, heigh, width);
    end
end
imcentro = imcentro & imgerode;
completo = bwperim(img);
centro = bwperim(imcentro);
se = strel('square', 2);
centro = imdilate(centro, se);

Rnew = regionprops(imcentro);

```

```

Hn = He; % desarrollo espectro
Area = 0;
for i = 1:length(Rnew)
    Area = Area + Rnew(i).Area;
end

spectro = zeros(1,240);
for i = 1:240
    Hn(:, :, i) = He(:, :, i). *double(imcentro);
    val = sum(sum(Hn(:, :, i))) / (Area);
    spectro(i) = val;
end

ref_I = interp1 (band, spectro, band_inter, 'line');
Ind(n,1)=(1./ref_I(7)-1./ref_I(10)); % ARI1=(1./R550-1./R700);
Ind(n,2)=ref_I(12).*(1./ref_I(7)-1./ref_I(10));
% ARI2=R800.*(1./R550-1./R700);
Ind(n,3)=(1./ref_I(4)-1./ref_I(7)); % CRI1=(1./R510-1./R550);
Ind(n,4)=(1./ref_I(4)-1./ref_I(10)); % CRI2=(1./R510-1./R700);
Ind(n,5)=(ref_I(6)-ref_I(8))/(ref_I(6)+ref_I(8));
% PRI=(R531-R570)/(R531+R570);
Ind(n,6)=(ref_I(9)-ref_I(3))/(ref_I(11)); % PSRI=(R680-R500)/(R750);

LinSVM = importdata('LinSVM.mat');
yfit = predict(LinSVM, Ind);
if yfit(n,1) == 1
    CRef(n,1) = {'morado'};
else
    CRef(n,1) = {'blanco'};
end
end
end

Ind = num2cell(Ind);
datos = [FileName' Ind CRef];
if number == 1
    datos = [FileName Ind CRef];
end
set(handles.Ind_table,'data',datos);
assignin('base','datos',datos)

t1 = nir + centro;
t2 = red + centro;
t3 = blue + centro;
im = im2uint16(cat(3,t1,t2,t3));
axes(handles.center);
cla
title('Area')
imshow(im)

axes(handles.spectro);
cla
plot(band,spectro,'b') % plot(band,spectro,'r')
title('Average spectrum')
set(gca,'XTick',[500,600,700,800])
set(gca,'YTick',[0.00,0.50,1.00])
axis([393 893 0.0 1.0])
grid on

```



### A-3: Código de clasificador Linear SVM

Archivo: LinSVMCode

```
function [trainedClassifier, validationAccuracy] =  
trainClassifier(datasetTable)  
% Convert input to table  
datasetTable = table(datasetTable);  
datasetTable.Properties.VariableNames = {'column'};  
% Split matrices in the input table into vectors  
datasetTable.column_1 = datasetTable.column(:,1);  
datasetTable.column_2 = datasetTable.column(:,2);  
datasetTable.column_3 = datasetTable.column(:,3);  
datasetTable.column_4 = datasetTable.column(:,4);  
datasetTable.column_5 = datasetTable.column(:,5);  
datasetTable.column_6 = datasetTable.column(:,6);  
datasetTable.column_7 = datasetTable.column(:,7);  
datasetTable.column = [];  
% Extract predictors and response  
predictorNames = {'column_1', 'column_2', 'column_3', 'column_4',  
'column_5', 'column_6'};  
predictors = datasetTable(:,predictorNames);  
predictors = table2array(varfun(@double, predictors));  
response = datasetTable.column_7;  
% Train a classifier  
trainedClassifier = fitcsvm(predictors, response, 'KernelFunction',  
'linear', 'PolynomialOrder', [], 'KernelScale', 'auto', 'BoxConstraint',  
1, 'Standardize', 1, 'PredictorNames', {'column_1' 'column_2' 'column_3'  
'column_4' 'column_5' 'column_6'}, 'ResponseName', 'column_7',  
'ClassNames', [1 2]);  
  
% Perform cross-validation  
partitionedModel = crossval(trainedClassifier, 'Kfold', 5);  
  
% Compute validation accuracy  
validationAccuracy = 1 - kfoldLoss(partitionedModel, 'LossFun',  
'ClassifError');  
  
%% Uncomment this section to compute validation predictions and scores:  
% % Compute validation predictions and scores  
% [validationPredictions, validationScores] =  
kfoldPredict(partitionedModel);
```

## Anexo B

**Tabla B-1: Base de datos de granos de color morado (color = 1)**

Base		Índices						COLOR
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI	
1	m1	0.26293904	0.1868603	0.30855263	0.57149167	-0.06060746	0.31551616	1
2	m2	0.21920661	0.17767557	0.245219	0.46442561	-0.05372672	0.28410248	1
3	m3	0.28355605	0.22092852	0.27642782	0.55998388	-0.05500827	0.29170877	1
4	m4	0.23173489	0.19533178	0.23601664	0.46775153	-0.05288801	0.27843365	1
5	m5	0.18126768	0.14190555	0.22539459	0.40666227	-0.05035418	0.25938416	1
6	m6	0.26815276	0.22508394	0.28403085	0.55218361	-0.05737387	0.30552803	1
7	m7	0.1409477	0.10513922	0.1982584	0.33920611	-0.04577229	0.23291116	1
8	m8	0.24052303	0.21023715	0.24708904	0.48761207	-0.05439167	0.29121785	1
9	m9	0.32926267	0.2831939	0.30884477	0.63810744	-0.05934682	0.32647966	1
10	m10	0.2846835	0.24032693	0.26114791	0.54583142	-0.05509188	0.29109929	1
11	m11	0.28390935	0.23089567	0.28883217	0.57274153	-0.05820132	0.30992192	1
12	m12	0.32794729	0.25704246	0.3121595	0.64010679	-0.06028736	0.3249705	1
13	m13	0.19891768	0.15742248	0.22373228	0.42264995	-0.0514875	0.26512453	1
14	m14	0.39477014	0.30974654	0.3524296	0.74719975	-0.05840314	0.33246849	1
15	m15	0.19691409	0.15042172	0.24531016	0.44222425	-0.0515744	0.26864538	1
16	m16	0.19206097	0.14101517	0.25959302	0.45165399	-0.05328519	0.27764173	1
17	m17	0.19486664	0.14861945	0.23420901	0.42907565	-0.05119741	0.26404518	1
18	m18	0.29265632	0.24470282	0.31538488	0.6080412	-0.06763752	0.34483426	1
19	m20	0.21859441	0.18041845	0.24837883	0.46697324	-0.05355978	0.2787214	1
20	m21	0.23750359	0.19285433	0.26687994	0.50438353	-0.05954058	0.30117844	1
21	m22	0.25082731	0.19800282	0.27131136	0.52213867	-0.05834248	0.29939818	1
22	m23	0.21095727	0.15453986	0.26734756	0.47830483	-0.05367399	0.27782637	1
23	m24	0.15855436	0.14019273	0.21624173	0.37479608	-0.05010832	0.25934302	1
24	m26	0.15959874	0.13443889	0.2363297	0.39592844	-0.05069729	0.26310601	1
25	m27	0.18940777	0.15775351	0.25659798	0.44600575	-0.05469498	0.28426006	1
26	m28	0.18532798	0.15481505	0.25141012	0.4367381	-0.0538813	0.2771974	1
27	m30	0.20589334	0.17750768	0.25535214	0.46124549	-0.05292492	0.27794759	1
28	m31	0.20565121	0.18245773	0.26667922	0.47233043	-0.05445176	0.2868496	1
29	m32	0.19513203	0.17385737	0.2391555	0.43428753	-0.05190584	0.27008031	1
30	m33	0.21869267	0.19517168	0.24708	0.46577267	-0.05284153	0.27770831	1
31	m35	0.16972313	0.13800118	0.22401471	0.39373784	-0.05059392	0.24896343	1
32	m36	0.25644376	0.21583445	0.28897372	0.54541747	-0.06130301	0.31377636	1
33	m37	0.22892755	0.18894949	0.28514112	0.51406867	-0.06058613	0.30172148	1
34	m38	0.20951107	0.17132108	0.24866303	0.4581741	-0.05417164	0.2737967	1

35	m39	0.24838442	0.19385547	0.29246112	0.54084555	-0.0594894	0.29528387	1
36	m40	0.28275737	0.24427129	0.31769285	0.60045022	-0.0662294	0.32781509	1
37	m41	0.18871098	0.15935255	0.23613678	0.42484776	-0.05220035	0.26508261	1
38	m42	0.24594897	0.2198293	0.26418454	0.5101335	-0.05613253	0.28931979	1
39	m43	0.23167995	0.19490189	0.27783641	0.50951636	-0.0564127	0.29010014	1
40	m44	0.20844295	0.1815315	0.22881773	0.43726069	-0.05228489	0.26460679	1
41	m45	0.21944965	0.19335224	0.2395221	0.45897175	-0.05424305	0.27485433	1
42	m46	0.18877383	0.15579813	0.24848645	0.43726027	-0.05762516	0.27974768	1
43	m48	0.09153908	0.06238747	0.22627762	0.31781669	-0.04150891	0.21428661	1
44	m50	0.21488747	0.18359319	0.26929548	0.48418295	-0.05730251	0.29479665	1
45	m51	0.18847752	0.16682184	0.23455169	0.42302921	-0.05442443	0.27698768	1
46	m53	0.22264548	0.17948268	0.26759771	0.4902432	-0.05642022	0.28331131	1
47	m54	0.19715719	0.17240026	0.23389333	0.43105052	-0.05114101	0.26812718	1
48	m56	0.21933224	0.19225951	0.25108964	0.47042189	-0.05561008	0.28380596	1
49	m57	0.24531909	0.2153646	0.29892625	0.54424534	-0.06287026	0.33730917	1
50	m59	0.29570658	0.24646262	0.30730895	0.60301552	-0.06274522	0.33657025	1
51	m78	0.17112327	0.15596441	0.17151176	0.34263503	-0.04598316	0.22361067	1
52	m85	0.20832858	0.18460864	0.18873078	0.39705937	-0.04586443	0.2268603	1
53	m96	0.172132	0.13713431	0.21175414	0.38388614	-0.0503743	0.24583663	1
54	m103	0.17333176	0.14922639	0.17645773	0.34978949	-0.04478533	0.22068715	1
55	m109	0.15575641	0.1436284	0.2132153	0.3689717	-0.05269212	0.24539939	1
56	m112	0.13394939	0.12472304	0.18231966	0.31626905	-0.04954018	0.22773843	1
57	m113	0.14859937	0.11698734	0.23052129	0.37912066	-0.05109955	0.24532221	1
58	m114	0.1660705	0.15326338	0.19884158	0.36491207	-0.04976206	0.23860847	1
59	m116	0.15759106	0.1246164	0.22350485	0.38109591	-0.05213194	0.24440205	1
60	m117	0.17240404	0.15803648	0.19710061	0.36950466	-0.05108615	0.24143761	1

Fuente: Elaboración propia.

**Tabla B-2: Base de datos de granos de color blanco (color = 2)**

Base		Índices						COLOR
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI	
61	m19	0.36192919	0.25606883	0.35416489	0.71609409	-0.06582716	0.35142722	2
62	m25	0.22148279	0.18946453	0.2739535	0.49543629	-0.05875001	0.31701499	2
63	m29	0.17498287	0.15734902	0.21280235	0.38778521	-0.05390968	0.28192273	2
64	m34	0.26727381	0.23766807	0.27428707	0.54156089	-0.0637237	0.33604216	2
65	m47	0.26399134	0.22147753	0.30311748	0.56710882	-0.06341483	0.33535664	2
66	m49	0.20665827	0.14298691	0.2708128	0.47747107	-0.05103607	0.27346277	2
67	m52	0.21237238	0.1894954	0.24639403	0.4587664	-0.05681017	0.30238197	2
68	m58	0.30060756	0.25348149	0.30177547	0.60238303	-0.05862873	0.30735867	2
69	m60	0.24038702	0.21216462	0.2703177	0.51070472	-0.05742777	0.31735617	2
70	m61	0.3070239	0.25939926	0.32014873	0.62717263	-0.06227432	0.34138965	2
71	m62	0.29895932	0.25480205	0.31521652	0.61417584	-0.06477586	0.34490059	2
72	m63	0.21702442	0.17988341	0.28693084	0.50395526	-0.05814834	0.29691747	2
73	m64	0.37857696	0.2958824	0.3999914	0.77856836	-0.07368459	0.37803479	2
74	m65	0.23652153	0.19925328	0.24301177	0.4795333	-0.05746158	0.28555239	2
75	m66	0.18706817	0.16235832	0.1927083	0.37977647	-0.04932618	0.24626081	2
76	m67	0.17654099	0.15362852	0.18809288	0.36463386	-0.04879152	0.24035946	2
77	m68	0.23007861	0.1904924	0.24849444	0.47857304	-0.05394755	0.27453121	2
78	m69	0.23006674	0.2032981	0.20671021	0.43677694	-0.05216325	0.26525971	2
79	m70	0.23603971	0.20801515	0.20854784	0.44458755	-0.05227787	0.26287568	2
80	m71	0.23433535	0.20123356	0.22178735	0.4561227	-0.05307688	0.27178171	2
81	m72	0.1894387	0.16926026	0.19941808	0.38885678	-0.05128834	0.25847886	2
82	m73	0.23331998	0.20255697	0.22133036	0.45465034	-0.05320603	0.27724534	2
83	m74	0.16677563	0.15263122	0.16899981	0.33577544	-0.04727134	0.23816887	2
84	m75	0.22319723	0.19538454	0.21109777	0.434295	-0.05196268	0.26687437	2
85	m76	0.2050545	0.18263783	0.18499458	0.39004908	-0.04780756	0.24767672	2
86	m77	0.17794853	0.15356718	0.1826892	0.36063774	-0.04731799	0.23729097	2
87	m79	0.27264988	0.23591821	0.23361886	0.50626875	-0.05508175	0.28478793	2
88	m80	0.19909022	0.16467791	0.212073	0.41116322	-0.04961221	0.2611618	2
89	m81	0.15608239	0.13533604	0.17424839	0.33033078	-0.04557104	0.22766848	2
90	m82	0.25503449	0.20999866	0.22899707	0.48403156	-0.05382285	0.27292054	2
91	m83	0.24896457	0.19959222	0.25264864	0.50161321	-0.05876991	0.2948051	2
92	m84	0.27066209	0.21507193	0.27269952	0.54336161	-0.06083361	0.30322489	2
93	m86	0.25181142	0.226688	0.23270729	0.4845187	-0.05663917	0.29032186	2
94	m87	0.17106929	0.15035001	0.17057649	0.34164579	-0.04550301	0.23166712	2
95	m88	0.23782102	0.21294856	0.21346223	0.45128324	-0.05272232	0.27523981	2
96	m89	0.22652692	0.20389471	0.1988379	0.42536483	-0.05193569	0.2635998	2

97	m90	0.21113929	0.16807466	0.22805188	0.43919116	-0.05234721	0.26232109	2
98	m91	0.16287331	0.14251806	0.18991942	0.35279273	-0.04970594	0.25087346	2
99	m93	0.26123098	0.23203764	0.24291014	0.50414111	-0.05792663	0.29479819	2
100	m94	0.24024882	0.2016068	0.2162366	0.45648542	-0.05109385	0.26689377	2
101	m97	0.2377645	0.21227797	0.22644805	0.46421255	-0.05537193	0.28245496	2
102	m98	0.20656027	0.15092198	0.22529566	0.43185593	-0.04913034	0.25181599	2
103	m99	0.17780794	0.15591648	0.18219725	0.36000519	-0.04872515	0.2400137	2
104	m100	0.19636014	0.16366221	0.19791938	0.39427952	-0.04879949	0.24567658	2
105	m101	0.21525851	0.18744202	0.20856594	0.42382445	-0.0528188	0.26845938	2
106	m102	0.18026209	0.15664899	0.18736639	0.36762848	-0.05010186	0.2454642	2
107	m104	0.24171456	0.21419729	0.22492114	0.4666357	-0.05495644	0.2838805	2
108	m105	0.31096086	0.26527522	0.26341544	0.5743763	-0.0588902	0.30537089	2
109	m106	0.24165831	0.19610601	0.23940354	0.48106185	-0.0543102	0.2778335	2
110	m107	0.22057721	0.17350004	0.22457754	0.44515475	-0.05072684	0.25649493	2
111	m108	0.23784253	0.20536336	0.28136176	0.51920429	-0.06236721	0.31615413	2
112	m110	0.21072854	0.18137761	0.23887038	0.44959892	-0.05566919	0.28434602	2
113	m111	0.16984152	0.14322892	0.2054115	0.37525301	-0.05076956	0.24767983	2
114	m115	0.16634021	0.14177138	0.20637035	0.37271055	-0.05198347	0.25403953	2
115	m119	0.16704208	0.14983444	0.19815112	0.3651932	-0.05362337	0.25396179	2
116	m120	0.18857272	0.16533421	0.2199717	0.40854442	-0.05470858	0.27329447	2
117	m124	0.17881622	0.16011227	0.22385639	0.40267261	-0.05567134	0.27884046	2
118	m125	0.1711878	0.14997341	0.20873607	0.37992387	-0.05378426	0.26326627	2
119	m128	0.19161096	0.16945141	0.20977629	0.40138724	-0.05183358	0.26431244	2
120	m129	0.21427451	0.17795493	0.24578503	0.46005954	-0.05561269	0.28564012	2

Fuente: Elaboración propia.

**Tabla B-3: Pruebas de validación de modelo Linear SVM**

Prueba		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m276	0.282650659	0.251620282	0.23929518	0.521945839	-0.046721256	0.273874609	1	1
2	m277	0.161144289	0.141673408	0.180214756	0.341359045	-0.040389498	0.224213219	1	1
3	m278	0.117367906	0.098561082	0.206469913	0.323837819	-0.044723139	0.242798314	1	1
4	m279	0.151369692	0.116647794	0.208701212	0.360070904	-0.039885306	0.230474095	1	1
5	m280	0.132636427	0.118538541	0.184741895	0.317378322	-0.04281571	0.232955025	1	1
6	m281	0.267487786	0.235596694	0.243344092	0.510831878	-0.04936803	0.280074791	1	1
7	m282	0.131434628	0.119698804	0.173701173	0.3051358	-0.040462918	0.227636411	1	1
8	m283	0.290953322	0.258400082	0.257354973	0.548308294	-0.049172875	0.279495534	1	1
9	m284	0.320425898	0.282769345	0.275512541	0.595938439	-0.053358947	0.296831137	1	1
10	m285	0.312875704	0.266543091	0.286592112	0.599467815	-0.053363676	0.299100094	1	1
11	m286	0.427411175	0.366300336	0.302503179	0.729914354	-0.053616011	0.307456939	1	1
12	m287	0.44254118	0.382442513	0.305865202	0.748406383	-0.05309737	0.305615174	1	1
13	m288	0.139774394	0.102460496	0.216512029	0.356286423	-0.039734446	0.22634229	1	1
14	m289	0.193202831	0.169521262	0.211411075	0.404613906	-0.04343436	0.250278221	1	1
15	m290	0.201105161	0.173052407	0.242595401	0.443700562	-0.047101648	0.268351082	1	1
16	m291	0.13465485	0.106851421	0.205169723	0.339824573	-0.04337527	0.235954879	1	1
17	m292	0.304122309	0.243538071	0.278524842	0.582647151	-0.051788131	0.29150829	1	1
18	m293	0.23788449	0.204369707	0.257982112	0.495866601	-0.050700667	0.283272618	1	1
19	m294	0.227843454	0.20325578	0.227589856	0.45543331	-0.047236812	0.267743199	1	1
20	m295	0.175860558	0.154254316	0.2109921	0.386852658	-0.04381083	0.24668485	1	1
21	m296	0.192937043	0.173026877	0.214267679	0.407204721	-0.04368511	0.246749317	1	1
22	m297	0.272882221	0.249594175	0.224606284	0.497488505	-0.048843327	0.270624187	1	1
23	m299	0.247315468	0.214766108	0.263603583	0.510919051	-0.051577219	0.285978152	1	1
24	m300	0.225665317	0.194140756	0.275328916	0.500994232	-0.050542644	0.288783297	1	1
25	m301	0.262182894	0.231811343	0.240607984	0.502790878	-0.047130348	0.269663566	1	1
26	m302	0.181355668	0.162439991	0.209233626	0.390589294	-0.044461518	0.250719688	1	1
27	m303	0.191772713	0.171921228	0.19544347	0.387216182	-0.04397001	0.244113724	1	1
28	m304	0.198392625	0.162832741	0.243436754	0.441829379	-0.048122661	0.277020103	1	1
29	m305	0.112285398	0.09827929	0.164405944	0.276691343	-0.037183451	0.204770255	1	1
30	m306	0.165284221	0.128085651	0.235125299	0.40040952	-0.045407553	0.258562078	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1
32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.22907133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1

39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2
49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2
56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	54
								%	90

Prueba		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m121	0.164694413	0.145117549	0.195036704	0.359731117	-0.04922398	0.237563337	1	1
2	m122	0.141660013	0.120801911	0.222419127	0.36407914	-0.054686884	0.257459912	1	1
3	m123	0.159699706	0.14460338	0.202510365	0.362210071	-0.051494563	0.237265163	1	1
4	m126	0.115621856	0.105328526	0.167455527	0.283077383	-0.04769135	0.214126579	1	1
5	m127	0.161074243	0.143191826	0.218578684	0.379652926	-0.053986005	0.251158376	1	1
6	m130	0.146252103	0.119632678	0.227255664	0.373507767	-0.051070685	0.242611622	1	1
7	m131	0.182682001	0.159574466	0.212598321	0.395280322	-0.051218903	0.248300203	1	1
8	m132	0.086464699	0.070346738	0.182377891	0.26884259	-0.043847586	0.205422138	1	1
9	m133	0.155978834	0.13605211	0.210978107	0.366956941	-0.053382171	0.251200589	1	1
10	m134	0.140910265	0.115515551	0.204433008	0.345343273	-0.051086306	0.235022005	1	1
11	m137	0.167209923	0.148379163	0.171762478	0.338972401	-0.041321409	0.2104348	1	1
12	m138	0.227550207	0.200807241	0.217541842	0.445092048	-0.039973375	0.225471374	1	1
13	m139	0.204809919	0.177861687	0.209943559	0.414753478	-0.040848328	0.22400484	1	1
14	m140	0.195992592	0.17148074	0.204420045	0.400412638	-0.040169643	0.220201963	1	1

15	m141	0.156582155	0.135227068	0.171735451	0.328317606	-0.042856337	0.210507654	1	1
16	m142	0.261786496	0.225865217	0.213908535	0.475695031	-0.04391708	0.247333903	1	1
17	m143	0.222462133	0.196395053	0.193813038	0.416275171	-0.043944298	0.232188604	1	1
18	m144	0.197939564	0.170818255	0.20202548	0.399965044	-0.041725914	0.225406898	1	1
19	m145	0.190617737	0.163878021	0.226169389	0.416787125	-0.046850582	0.245253241	1	1
20	m146	0.22852768	0.183530403	0.226013771	0.45454145	-0.045269006	0.243939419	1	1
21	m147	0.279566079	0.243334547	0.228543803	0.508109882	-0.040428703	0.249354536	1	1
22	m148	0.214845787	0.176714256	0.215992415	0.430838202	-0.042090638	0.233325895	1	1
23	m151	0.220203873	0.189129602	0.207402443	0.427606316	-0.040775218	0.233899634	1	1
24	m152	0.235523299	0.176296421	0.243792664	0.479315963	-0.044268913	0.233517169	1	1
25	m154	0.183773709	0.156699216	0.192229171	0.37600288	-0.041667426	0.212285901	1	1
26	m155	0.236284588	0.20639263	0.196996835	0.433281423	-0.041306443	0.237853966	1	1
27	m157	0.271433878	0.233219043	0.229135588	0.500569466	-0.042772592	0.247376275	1	1
28	m158	0.185320835	0.160340362	0.199512013	0.384832849	-0.043408969	0.226704063	1	1
29	m160	0.177358686	0.141675481	0.209253295	0.386611981	-0.043462033	0.215036755	1	1
30	m161	0.238896876	0.193629119	0.232729117	0.471625993	-0.048403167	0.252598251	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1
32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.22907133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1
39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2
49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2



56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	54
								%	90

Prueba		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m162	0.2008345	0.176079439	0.240832997	0.441667497	-0.047356719	0.251852128	1	1
2	m163	0.162745314	0.142104573	0.181340892	0.344086206	-0.042651496	0.22118236	1	1
3	m164	0.196141817	0.157394512	0.235326774	0.431468591	-0.046164201	0.242809405	1	1
4	m165	0.177066938	0.121739887	0.205661769	0.382728707	-0.035674944	0.199443751	1	1
5	m168	0.278288597	0.246502377	0.235199388	0.513487985	-0.047742364	0.261807175	1	1
6	m169	0.127777196	0.112808457	0.171461197	0.299238393	-0.039663985	0.2013477	1	1
7	m170	0.274489399	0.24213208	0.247281031	0.521770429	-0.04837046	0.262625059	1	1
8	m171	0.243984721	0.214836124	0.209884215	0.453868936	-0.042773438	0.238268002	1	1
9	m172	0.247533068	0.221357119	0.235800756	0.483333825	-0.045671509	0.247064861	1	1
10	m173	0.254323342	0.212379255	0.266064282	0.520387624	-0.051942907	0.274909118	1	1
11	m174	0.21712306	0.16235706	0.232505315	0.449628376	-0.042141044	0.227781608	1	1
12	m179	0.473497422	0.409663871	0.453775787	0.927273209	-0.095772598	0.391397967	1	1
13	m182	0.487550385	0.43478137	0.444424221	0.931974606	-0.098942109	0.401954636	1	1
14	m184	0.246124052	0.185944358	0.287261638	0.53338569	-0.063488012	0.292888182	1	1
15	m185	0.545373805	0.476435468	0.470415217	1.015789022	-0.100009584	0.409152991	1	1
16	m186	0.527387235	0.456640776	0.471681743	0.999068978	-0.103850264	0.411795103	1	1
17	m189	0.528118481	0.408980266	0.504100835	1.032219316	-0.095080115	0.412327913	1	1
18	m190	0.613944097	0.519299362	0.531984864	1.145928962	-0.098020669	0.41926141	1	1
19	m191	0.597813747	0.520531836	0.529196293	1.127010039	-0.101273582	0.41794189	1	1
20	m192	0.593435237	0.533786189	0.515033696	1.108468934	-0.102357032	0.42452376	1	1
21	m194	0.782538572	0.633311878	0.680109301	1.462647872	-0.105327926	0.451998732	1	1
22	m197	0.347184246	0.296743541	0.323878418	0.671062665	-0.074401334	0.330525075	1	2
23	m198	0.347385214	0.312389108	0.334307985	0.681693199	-0.083271894	0.350653966	1	2
24	m199	0.353201803	0.286711402	0.36123136	0.714433163	-0.081223275	0.358021814	1	2
25	m203	0.353932957	0.319457429	0.320892803	0.674825761	-0.079910658	0.345086988	1	2
26	m205	0.318187707	0.289884377	0.316724117	0.634911824	-0.08453414	0.352885486	1	2
27	m206	0.533988478	0.447704799	0.458116616	0.992105094	-0.088350564	0.389879741	1	1
28	m207	0.199559249	0.159439048	0.262577522	0.462136771	-0.06000289	0.273243999	1	1
29	m209	0.093945396	0.081020648	0.164577805	0.258523202	-0.041725881	0.210565426	1	1
30	m210	0.078297907	0.071075865	0.132499963	0.21079787	-0.034980736	0.173777883	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1

32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.22907133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1
39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2
49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2
56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	49
								%	81.7

Prueba		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m211	0.058133978	0.051794778	0.125045038	0.183179016	-0.035743609	0.167483656	1	1
2	m212	0.147376508	0.12774963	0.206859356	0.354235863	-0.049888021	0.256841921	1	1
3	m213	0.163613142	0.148139881	0.17828715	0.341900292	-0.042367814	0.223945248	1	1
4	m214	0.162984696	0.151425576	0.170542844	0.333527539	-0.039706289	0.215266299	1	1
5	m215	0.139507636	0.116488329	0.186032614	0.32554025	-0.044768976	0.233110323	1	1
6	m216	0.14677136	0.138681747	0.148257519	0.295028879	-0.040667694	0.213428945	1	1
7	m217	0.135528833	0.113787765	0.176748596	0.31227743	-0.042226785	0.219410763	1	1

8	m218	0.089113879	0.074643294	0.158444708	0.247558587	-0.038687712	0.193304611	1	1
9	m219	0.131748703	0.10938102	0.169624704	0.301373408	-0.041418913	0.211593073	1	1
10	m220	0.078350432	0.069236533	0.149820385	0.228170817	-0.039920307	0.195156849	1	1
11	m221	0.11253317	0.100900711	0.156457892	0.268991062	-0.040742459	0.207090038	1	1
12	m222	0.129701206	0.113571143	0.175098028	0.304799234	-0.044511792	0.228717404	1	1
13	m223	0.135633538	0.120453697	0.170317097	0.305950635	-0.042322434	0.217345558	1	1
14	m224	0.176607648	0.152635564	0.186759046	0.363366694	-0.046381371	0.245769047	1	2
15	m225	0.212504974	0.187698306	0.20195411	0.414459084	-0.044943368	0.24520888	1	1
16	m226	0.138997712	0.124814962	0.168090607	0.30708832	-0.042148484	0.217668695	1	1
17	m227	0.145764559	0.127994728	0.196449207	0.342213766	-0.047883082	0.245300931	1	1
18	m228	0.132533486	0.119209757	0.161128552	0.293662038	-0.040202565	0.215647599	1	1
19	m229	0.10748516	0.092574918	0.161033259	0.268518419	-0.040699817	0.208071762	1	1
20	m230	0.183917628	0.152952155	0.227683884	0.411601512	-0.047149462	0.255796372	1	1
21	m232	0.121496539	0.110410362	0.188253606	0.309750144	-0.048666734	0.24623021	1	2
22	m233	0.112828599	0.102967921	0.171246942	0.28407554	-0.045220033	0.231969322	1	1
23	m234	0.123237689	0.111248862	0.197374911	0.3206126	-0.050928365	0.257688681	1	2
24	m235	0.106411726	0.099513885	0.155078041	0.261489767	-0.043583196	0.21396033	1	1
25	m237	0.156854824	0.147991231	0.190241891	0.347096715	-0.050076459	0.24639974	1	2
26	m238	0.128560044	0.120867328	0.16749879	0.296058834	-0.045110452	0.229648294	1	2
27	m239	0.115008719	0.107776749	0.164994521	0.280003239	-0.046113262	0.223011073	1	1
28	m240	0.183730722	0.160225206	0.21004637	0.393777092	-0.048886427	0.253356037	1	1
29	m242	0.125367963	0.114888347	0.174865615	0.300233578	-0.045734323	0.22593646	1	1
30	m243	0.135597906	0.118695523	0.187296288	0.322894194	-0.047883059	0.236959162	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1
32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.22907133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1
39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2

49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2
56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	49
								%	81.7

Prueba		Índices						Dato real	Dato SVM
Grano	Etiqueta	ARI1	ARI2	CRI1	CRI2	PRI	PSRI		
1	m244	0.160497012	0.148660568	0.191288899	0.351785911	-0.049162099	0.249555839	1	2
2	m245	0.120953595	0.108389406	0.17973206	0.300685655	-0.046142593	0.228615086	1	1
3	m247	0.237560656	0.221985944	0.213396449	0.450957106	-0.047038665	0.261708822	1	1
4	m249	0.146739864	0.140689831	0.173154393	0.319894256	-0.044935781	0.232558807	1	1
5	m251	0.17797745	0.156885204	0.220330777	0.398308227	-0.05005218	0.254473631	1	1
6	m252	0.126653865	0.110946253	0.185608552	0.312262417	-0.045482073	0.232835254	1	1
7	m253	0.17542176	0.159815829	0.229729037	0.405150797	-0.053231306	0.27633466	1	1
8	m256	0.115234676	0.098917823	0.184023282	0.299257958	-0.045655897	0.229433882	1	1
9	m257	0.0859956	0.08035991	0.144996359	0.230991959	-0.040475247	0.198985763	1	1
10	m258	0.135900501	0.125664366	0.195219408	0.331119909	-0.052597656	0.257140741	1	2
11	m259	0.082623577	0.079702612	0.141219253	0.22384283	-0.041626055	0.19873829	1	1
12	m260	0.172384361	0.159029169	0.21406086	0.386445222	-0.053653934	0.273783613	1	2
13	m262	0.232310638	0.206476744	0.212727959	0.445038596	-0.047501474	0.261210699	1	1
14	m263	0.290191721	0.245359316	0.251111539	0.54130326	-0.046154634	0.277270672	1	1
15	m264	0.184907629	0.164474793	0.196142874	0.381050503	-0.042342644	0.242179517	1	1
16	m265	0.173152848	0.140384879	0.220460377	0.393613225	-0.044762302	0.254789777	1	1
17	m266	0.189189484	0.148660031	0.236064711	0.425254195	-0.042296088	0.25514798	1	1
18	m267	0.247075166	0.212191078	0.251141871	0.498217037	-0.048906505	0.274722252	1	1
19	m268	0.215852897	0.193938493	0.200227731	0.416080628	-0.044619392	0.251623967	1	1
20	m269	0.187236531	0.166167344	0.214112885	0.401349416	-0.046796065	0.258932429	1	1
21	m270	0.366629018	0.319704695	0.303514044	0.670143062	-0.058084014	0.311231823	1	1
22	m271	0.118722014	0.102601855	0.179039521	0.297761535	-0.039723652	0.222871382	1	1
23	m272	0.142389327	0.127566683	0.181787886	0.324177213	-0.041159706	0.227988253	1	1
24	m273	0.211861941	0.185453985	0.204399051	0.416260991	-0.043881463	0.24554168	1	1

25	m274	0.296367263	0.266491651	0.254737209	0.551104472	-0.05271247	0.286872331	1	1
26	m276	0.282650659	0.251620282	0.23929518	0.521945839	-0.046721256	0.273874609	1	1
27	m277	0.161144289	0.141673408	0.180214756	0.341359045	-0.040389498	0.224213219	1	1
28	m278	0.117367906	0.098561082	0.206469913	0.323837819	-0.044723139	0.242798314	1	1
29	m279	0.151369692	0.116647794	0.208701212	0.360070904	-0.039885306	0.230474095	1	1
30	m280	0.132636427	0.118538541	0.184741895	0.317378322	-0.04281571	0.232955025	1	1
31	m135	0.195940006	0.146746286	0.261148411	0.457088417	-0.054608735	0.271667081	2	1
32	m136	0.220228889	0.195609933	0.216312157	0.436541047	-0.049499415	0.271456203	2	2
33	m149	0.288012638	0.24869156	0.269926777	0.557939415	-0.055260764	0.309572552	2	2
34	m150	0.218775401	0.191740474	0.206221668	0.424997068	-0.046796493	0.267158605	2	2
35	m153	0.155781597	0.126328446	0.191160261	0.346941859	-0.045696279	0.232617847	2	1
36	m159	0.236040281	0.206252126	0.22907133	0.465111611	-0.051613516	0.282193958	2	2
37	m166	0.204004671	0.179442821	0.191126913	0.395131584	-0.043555003	0.253410162	2	2
38	m167	0.271092183	0.221099107	0.243767633	0.514859816	-0.049908362	0.279785491	2	1
39	m175	0.480690078	0.419484265	0.445573097	0.926263175	-0.100104178	0.415815074	2	2
40	m176	0.47369102	0.40294725	0.4256514	0.89934242	-0.098728235	0.403839694	2	2
41	m177	0.285393039	0.236506605	0.283368694	0.568761733	-0.072198345	0.322447933	2	2
42	m178	0.427123983	0.376494639	0.377482684	0.804606668	-0.09134913	0.388076562	2	2
43	m180	0.453079004	0.417892225	0.377501423	0.830580427	-0.091700055	0.400264745	2	2
44	m181	0.537805164	0.48091119	0.494949807	1.032754971	-0.108048036	0.443841066	2	2
45	m183	0.433891505	0.370924552	0.376197145	0.810088651	-0.085591871	0.387698319	2	2
46	m195	0.706705759	0.625219263	0.587988607	1.294694366	-0.110790322	0.46347089	2	1
47	m196	0.505826506	0.450741069	0.41194655	0.917773056	-0.090128914	0.40905184	2	2
48	m200	0.382950424	0.350881661	0.346314102	0.729264526	-0.086598674	0.384782234	2	2
49	m201	0.451350761	0.40564561	0.405813766	0.857164527	-0.095855676	0.414006982	2	2
50	m202	0.418978479	0.381226196	0.383199884	0.802178363	-0.092740475	0.404450143	2	2
51	m204	0.473713487	0.440941545	0.409765937	0.883479424	-0.096884036	0.41792528	2	2
52	m208	0.326787606	0.275873765	0.320781551	0.647569157	-0.073916795	0.354713859	2	2
53	m231	0.096434619	0.084072577	0.154821036	0.251255655	-0.04174112	0.211900023	2	1
54	m236	0.137025443	0.132574946	0.155708518	0.292733961	-0.046219101	0.239638493	2	2
55	m241	0.2101214	0.185813024	0.227327265	0.437448665	-0.054697033	0.289132843	2	2
56	m246	0.184398941	0.170402076	0.208285183	0.392684125	-0.052285631	0.275778556	2	2
57	m250	0.173766371	0.16684315	0.192754744	0.366521115	-0.051403907	0.268961663	2	2
58	m254	0.168937712	0.159534069	0.211929137	0.380866848	-0.053483976	0.283454249	2	2
59	m261	0.128318565	0.110148542	0.182261652	0.310580217	-0.046396869	0.236622674	2	1
60	m275	0.323531534	0.286033879	0.277551176	0.60108271	-0.054893195	0.316786534	2	2
								Aciertos	51
								%	85
								% Prom	85.7

Fuente: Elaboración propia.