

**UNIVERSIDAD POLITÉCNICA DE VALENCIA**  
**INSTITUTO UNIVERSITARIO DE INGENIERÍA DE**  
**ALIMENTOS PARA EL DESARROLLO**



**APLICACIÓN DE LA TECNOLOGÍA DE IMÁGENES**  
**HIPERESPECTRALES AL CONTROL DE CALIDAD DE PRODUCTOS**  
**AGROALIMENTARIOS DE LA REGIÓN DE**  
**AMAZONAS (PERÚ)**

**TESIS DOCTORAL**

**Presentada por:**  
**WILSON MANUEL CASTRO SILUPU**

**Dirigida por:**  
**DR. PEDRO J. FITO MAUPOEY**

**DRA. LUCIA SEGUÍ GIL**

**DR. LUIS MAYOR LÓPEZ**

**VALENCIA, 2015**





**UNIVERSITAT POLITÈCNICA DE VALÈNCIA**  
**INSTITUTO UNIVERSITARIO DE INGENIERÍA DE**  
**ALIMENTOS PARA EL DESARROLLO**

EL **Dr. PEDRO FITO MAUPOEY**, PROFESOR EMÉRITO, LA **Dra. LUCIA SEGUÍ GIL** PROFESORA CONTRATADA DOCTORA Y MIEMBRO DEL INSTITUTO U. DE INGENIERÍA DE ALIMENTOS PARA EL DESARROLLO DE LA UNIVERSITAT POLITÈCNICA DE VALÈNCIA Y EL **Dr. LUIS MAYOR LÓPEZ**:

**CONSIDERAN:** Que la memoria titulada APLICACIÓN DE LA TECNOLOGÍA DE IMÁGENES HIPERESPECTRALES AL CONTROL DE CALIDAD DE PRODUCTOS AGROALIMENTARIOS DE LA REGIÓN DE AMAZONAS (PERÚ) que presenta **D. WILSON MANUEL CASTRO SILUPU** para aspirar al grado de Doctor por la Universitat Politècnica de València, y que ha sido realizada bajo su dirección, reúne las condiciones adecuadas para constituir su tesis doctoral, por lo que **AUTORIZAN** al interesado para su presentación.

Valencia, Octubre de 2015

Fdo. D. PEDRO JOSÉ FITO MAUPOEY  
Director de tesis

Fdo. Da. LUCIA SEGUÍ GIL  
Directora de tesis

Fdo. D. LUIS MAYOR LÓPEZ  
Director de tesis



## *Dedicatoria*

*Les dedico esta tesis a  
Katty, a Diana y  
Gisela por el tiempo que  
no les pude dedicar  
mientras hice este  
trabajo*

*A mi madre, hermanos,  
compañeros y amigos  
por su continuo apoyo  
al logro de mis metas*



## ***AGRADECIMIENTOS***

La culminación de esta tesis doctoral me ha brindado la oportunidad de desarrollarme tanto a nivel académico como profesional y en su desarrollo he vertido dedicación, esfuerzo, paciencia y amor. Pero no hubiera podido culminar la misma sin la ayuda que proveyeron tanto personas como entidades en diversos planos de las actividades de esta tesis. Es así que en las siguientes líneas dejaré constancia de mi agradecimiento personal por la experiencia que me tocó vivir con cada uno de ellos:

Al proyecto "Aplicación de técnica de imágenes hiperespectrales de la calidad en productos agropecuarios de la región Amazonas" financiado por el Fondo para la Innovación, Ciencia y Tecnología (FINCyT) mediante el Contrato 220-FINCyT-IA-2013 y ejecutado en la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas (UNTRM). Al equipo del proyecto Ivest Julian Yoplac Tafur, Raúl Benito Siche Jara, Veronica Zuta Chamoli, César López Portocarrero y Melisa Pizarro Paredes por sus aportes y su esfuerzo en el desarrollo de este proyecto y en mérito a lo cual me ha sido posible presentar esta memoria de tesis.

A mis directores Pedro Fito Maupoey, Lucia Seguí Gil y Luis Mayor López por introducirme en el mundo de la investigación, por guiarme en el camino al logro de este proyecto. He recibido de ustedes la valiosa oportunidad de formarme bajo su tutela y no me dejaré de sorprender su poder de análisis y su entusiasmo en cada proyecto que emprenden.

A mis hijas, Katty Camila, a Diana Katherine y a mi compañera y amiga Gisela, quienes aportaron con su paciencia y comprensión para culminar esta etapa de mi vida.

A mis padres Manuel Castro Meza e Yda Silupu Gutiérrez, a mis hermanos Alex, Magdalena, Jorge y Susy quienes con su apoyo incondicional y su ejemplo de vida me ayudaron a cumplir estos sueños; mostrándome que, aún a pesar de lo adverso que se mostrara el destino, el único límite a nuestros sueños es el cielo.

A todos los compañeros de la Facultad de Ingeniería Zootecnista, Agronegocios y Biotecnología de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas por su colaboración.

## RESUMEN

La evaluación de la calidad de los productos agroalimentarios es una preocupación constante por parte de los diversos actores de la cadena agroproductiva y requiere del uso de una serie de métodos físicos, químicos, bioquímicos y sensoriales, los cuales son destructivos, demandan mucho tiempo, son costosos, laboriosos y en el caso de los sensoriales subjetivos, lo cual dificulta su aplicación en procesos en línea. Frente a las metodologías tradicionales, la tecnología de imágenes hiperespectrales surge como una herramienta no destructiva de evaluación de la calidad. En la Región Amazonas (Perú) la evaluación de la calidad se realiza con las metodologías tradicionales, lo cual presenta importantes limitaciones como, por ejemplo, la detección tardía de infecciones en cultivos, caso de la roya del café; la imposibilidad de determinar adulteraciones, caso de la presencia de almidón en queso fresco; o bien, la clasificación subjetiva según estándares de calidad, caso del marmoleado de carne de res. Por otro lado, la aplicación de la tecnología de imágenes hiperespectrales requiere de una serie de pasos para la obtención, procesado y análisis de la información, los cuales han sido desarrollados y aplicados por diversos investigadores, pero han sido unificados en un solo sistema y procedimiento para su uso por usuarios no familiarizados con la profundidad del análisis informático. En este contexto, la presente tesis doctoral se plantea con el fin de desarrollar una aplicación informática para el uso de la tecnología de imágenes hiperespectrales en la evaluación de la calidad de tres productos agroalimentarios de la Región Amazonas (Perú). Para ello, fue necesario crear una serie de subsistemas, módulos y rutinas, que posteriormente fueron implementarlas, mediante ventanas de usuario (Guides) y funciones, empleando el software matemático Matlab 2010<sup>a</sup>. La

aplicabilidad del sistema desarrollado se probó en tres casos de estudio: detección del grado de infección por roya en muestras de hojas de café, detección de la adulteración en muestras de queso fresco con almidón a distintas concentraciones, y clasificación según estándares de marmoleado de muestras de carne de res. Como resultados del desarrollo del sistema las herramientas informáticas desarrolladas se implementaron en un software que permite fácil uso de las mismas y compatible con el sistema de adquisición de imágenes mediante reflectancia. Una versión avanzada del software podría ser patentada y transferida a la industria, en una fase posterior a la realización de esta tesis doctoral. Dicho software podría ser diseñado de tal forma que pudiera incluir de forma progresiva nuevas herramientas útiles en el control de calidad de otros procesos agroalimentarios. En cuanto a los casos estudiados; los resultados del análisis de la infección temprana por roya, en hojas de café, muestra diferencias estadísticamente significativas con respecto al análisis por jueces, atribuible a la mayor sensibilidad del sistema. Para el análisis de la adulteración se demostró que la aplicación de la técnica de imágenes hiperespectrales permite detectar la adulteración por harina de maíz en queso fresco, en base a la relación entre la reflectancia y el contenido de almidón en muestras de queso fresco. Asimismo, la metodología implementada, basada en tecnología de imágenes hiperespectrales, probó ser válida para la determinación de la calidad de carne de res en base a la norma japonesa de marmoleado.

## RESUMEN

La evaluación de la calidad de los productos agroalimentarios es una preocupación constante para los diversos actores de la cadena agroproductiva y requiere del uso de una serie de métodos de análisis: físicos, químicos, bioquímicos y sensoriales; los cuales son destructivos, demandan mucho tiempo, son costosos, laboriosos y, en el caso de los sensoriales, subjetivos, lo cual dificulta su aplicación en procesos en línea. Frente a las metodologías tradicionales, la tecnología de imágenes hiperespectrales surge como una herramienta no destructiva de evaluación de la calidad. En la Región Amazonas (Perú) la evaluación de la calidad se realiza con las metodologías tradicionales, lo cual presenta importantes limitaciones como, por ejemplo, la detección tardía de infecciones en cultivos, caso de la roya del café; la imposibilidad de determinar adulteraciones, caso de la presencia de almidón en queso fresco; o bien, la clasificación subjetiva según estándares de calidad, caso del marmoleado de carne de res. Por otro lado, la aplicación de la tecnología de imágenes hiperespectrales requiere de una serie de pasos para la obtención, procesamiento y análisis de la información, los cuales han sido desarrollados y aplicados por diversos investigadores, pero que no han sido unificados en un sistema y procedimiento para su uso por usuarios no familiarizados con la profundidad del análisis informático. En este contexto, la presente tesis doctoral se plantea con el fin de desarrollar una aplicación informática para el uso de la tecnología de imágenes hiperespectrales en la evaluación de la calidad de tres productos agroalimentarios de la Región Amazonas (Perú). Para ello, fue necesario crear una serie de subsistemas, módulos y rutinas, que posteriormente fueron implementadas mediante ventanas de usuario (Guides) y funciones, empleando el

software matemático Matlab 2010<sup>a</sup>. La aplicabilidad del sistema desarrollado se probó en tres casos de estudio: detección del grado de infección por roya en muestras de hojas de café, detección de la adulteración en muestras de queso fresco con almidón a distintas concentraciones, y clasificación según estándares de marmoleado de muestras de carne de res. Como resultado del desarrollo del sistema, las herramientas informáticas desarrolladas se implementaron en un software que permite fácil uso de las mismas y que es compatible con el sistema de adquisición de imágenes mediante en modo de reflectancia. En cuanto a los casos estudiados, los resultados del análisis de la infección temprana por roya en hojas de café, muestran diferencias estadísticamente significativas con respecto al análisis por jueces, atribuibles a la mayor sensibilidad del sistema. Para el análisis de la adulteración queso fresco se ha demostrado que la aplicación de la técnica de imágenes hiperespectrales permite detectar la adulteración por harina de maíz en queso fresco, en base a la relación entre la reflectancia y el contenido de almidón en muestras de queso fresco. Asimismo, la metodología implementada, basada en tecnología de imágenes hiperespectrales, probó ser válida para la determinación de la calidad de carne de res en base a la norma japonesa de marmoleado. Una versión avanzada del software podría ser patentada y transferida a la industria, en una fase posterior a la realización de esta tesis doctoral. Dicho software podría ser diseñado de tal forma que pudiera incluir de forma progresiva nuevas herramientas útiles en el control de calidad de otros procesos agroalimentarios.

## RESUM

L'avaluació de la qualitat dels productes agroalimentaris és una preocupació constant per als diversos actors de la cadena agroproductiva i requereix de l'ús d'una sèrie de mètodes d'anàlisi: físics, químics, bioquímics i sensorials; els quals són destructius, demanden molt temps, són costosos, laboriosos i, en el cas dels sensorials, subjectius, la qual cosa dificulta la seua aplicació en processos en línia. Enfront de les metodologies tradicionals, la tecnologia d'imatges hiperespectrals sorgeix com una eina no destructiva d'avaluació de la qualitat. En la Regió Amazones (Perú) l'avaluació de la qualitat es realitza amb les metodologies tradicionals, la qual cosa presenta importants limitacions com, per exemple, la detecció tardana d'infeccions en cultius, cas de la roia del cafè; la impossibilitat de determinar adulteracions, cas de la presència de midó en formatge fresc; o bé, la classificació subjectiva segons estàndards de qualitat, cas del marmolejat de carn de cap de bestiar. D'altra banda, l'aplicació de la tecnologia d'imatges hiperespectrals requereix d'una sèrie de passos per a l'obtenció, processament i anàlisi de la informació, els quals han sigut desenvolupats i aplicats per diversos investigadors, però que no han sigut unificats en un únic sistema i procediment per al seu ús per usuaris no familiaritzats amb la profunditat de l'anàlisi informàtica. En aquest context, la present tesi doctoral es planteja amb la finalitat de desenvolupar una aplicació informàtica per a l'ús de la tecnologia d'imatges hiperespectrals en l'avaluació de la qualitat de tres productes agroalimentaris de la Regió Amazones (Perú). Per a açò, va ser necessari crear una sèrie de subsistemes, mòduls i rutines, que posteriorment van ser implementades mitjançant finestres d'usuari (Guides) i funcions, emprant el programari matemàtic Matlab 2010<sup>a</sup>. L'aplicabilitat del sistema desenvolupat es va provar en tres casos d'estudi: detecció del grau d'infecció per roia en mostres de fulles de cafè,

detecció de l'adulteració en mostres de formatge fresc amb midó a diferents concentracions, i classificació segons estàndards de marmolejat de mostres de carn de cap de bestiar. Com a resultat del desenvolupament del sistema, les eines informàtiques desenvolupades es van implementar en un programari que permet un fàcil ús de les mateixes i que és compatible amb el sistema d'adquisició d'imatges mitjançant reflectància. Quant als casos estudiats, els resultats de l'anàlisi de la infecció primerenca per roia en fulles de cafè, mostren diferències estadísticament significatives pel que fa a l'anàlisi per jutges, atribuïbles a la major sensibilitat del sistema. Per a l'anàlisi de l'adulteració formatge fresc s'ha demostrat que l'aplicació de la tècnica d'imatges hiperespectrals permet detectar l'adulteració per farina de dacsca en formatge fresc, sobre la base de la relació entre la reflectància i el contingut de midó en mostres de formatge fresc. Així mateix, la metodologia implementada, basada en tecnologia d'imatges hiperespectrals, va provar ser vàlida per a la determinació de la qualitat de carn de cap de bestiar sobre la base de la norma japonesa de marmolejat. Una versió avançada del programari podria ser patentada i transferida a la indústria, en una fase posterior a la realització d'aquesta tesi doctoral. Aquest programari podria ser dissenyat de tal forma que poguera incloure de forma progressiva noves eines útils en el control de qualitat d'altres processos agroalimentaris.

## **ABSTRACT**

The evaluation of the quality of food products is a constant concern for the different actors in the production chain and requires the use of a number of analytical methods: physical, chemical, biochemical and sensory; which are destructive, time-consuming, are expensive, laborious and, in the case of sensory, subjective, which makes its application process online. Unlike traditional methodologies, hyperspectral imaging technology emerges as a non-destructive tool for quality assessment. In the Amazon Region (Peru) quality evaluation is performed with traditional methodologies, which has significant limitations as, for example, late detection of infections in crops, if coffee rust; the inability to determine adulteration, if the presence of starch in cheese; or, the subjective classification as quality standards, case marbling of beef. On the other hand, the application of hyperspectral imaging technology requires a series of steps for obtaining, processing and analysing information, which have been developed and implemented by various researchers, but have not been unified in one system and procedures for use by users unfamiliar with the depth of the computer analysis. In this context, this thesis has been planned in order to develop an IT application for the use of hyperspectral imaging technology to assess the quality of three food products in the Amazon Region (Peru). For this purpose it was necessary to create a number of subsystems, modules and routines, which were subsequently implemented by user windows (Guides) and functions using the mathematical software Matlab 2010<sup>a</sup>. The applicability of the developed system was tested in three case studies: detecting the degree of rust infection in samples of coffee leaves detecting adulteration in samples of fresh cheese with starch at different concentrations, and classification according to samples marbling standards beef. As a result of the system development, the developed

IT tools were implemented in a software that allows easy use of them and that is compatible with the system by reflectance imaging. As for the cases studied, the analysis results of early infection coffee leaf rust, showed statistically significant differences from the analysis judges attributable to the increased sensitivity of the system. For the analysis of fresh cheese adulteration has been shown that the application of the hyperspectral imaging technique to detect adulteration cornmeal in cheese, based on the relationship between the reflectance and the starch content in samples of fresh cheese. Also, the implemented methodology, based on hyperspectral imaging technology, proved to be valid for the determination of the quality of beef based on the Japanese standard of marbling. An advanced version of the software could be patented and transferred to industry, at a later stage to the realization of this thesis. Such software could be designed so that could include progressively new useful tools in quality control of other agro-food processes.

# INDICE GENERAL

Nomenclatura*	1
1. Aplicaciones de la técnica de imágenes hiperespectrales en la agricultura y procesos agroalimentarios	3
1.1. Introducción	4
1.2. Aspectos generales	6
1.3. Concepto de imagen hiperespectral	7
1.3.1. Avances en sistemas de adquisición de imágenes hiperespectrales	13
1.3.2. Modos de detección y escaneo de imágenes hiperespectrales	18
1.3.3. Ventajas y desventajas de la técnica de imágenes hiperespectrales	19
1.4. Aplicaciones de los sistemas de imágenes hiperespectrales	20
1.5. En agricultura y control de semillas	22
1.5.1. En el procesamiento postcosecha	25
1.5.2. En productos hortofrutícolas mínimamente procesados	31
1.6. Proyección futura y retos	33
1.7. Conclusión	34
Referencias bibliográficas	35
2. Materiales y métodos	52
2.1. Introducción	53
2.2. Montaje y puesta a punto del sistema de adquisición de imágenes hiperespectrales	53
2.2.1. Hardware	54
2.3. Software de adquisición de datos	57
2.4. Puesta en marcha del sistema de adquisición de imágenes	60
2.5. Cargado de imágenes para corrección espacial	61
2.6. Adquisición de imágenes	62

2.7.	Segmentación por umbralizado .....	63
2.8.	Conclusiones.....	65
	Referencias bibliográficas.....	66
3.	Desarrollo de aplicación informática para pre-procesamiento y análisis de imágenes hiperespectrales .....	68
3.1.	Introducción .....	69
3.2.	Materiales y métodos.....	71
3.2.1.	Materiales.....	71
3.2.2.	Metodología .....	72
3.2.2.1.	Desarrollo de requerimientos .....	73
3.2.2.2.	Desarrollo de la arquitectura del sistema .....	74
3.2.2.3.	Validación de secuencias lógicas .....	77
3.2.2.4.	Implementación del software .....	77
3.3.	Resultados y discusión.....	78
3.3.1.	Requerimientos operacionales.....	78
3.3.2.	Características operacionales.....	78
3.3.3.	Especificaciones técnicas o requerimientos del sistema.....	81
3.3.3.1.	Interfaces o ventanas .....	81
3.3.3.2.	Restricciones de diseño .....	82
3.3.4.	Desarrollo de la arquitectura del sistema .....	82
3.3.4.1.	Nivel 1: Sistema del software .....	83
3.3.4.2.	Nivel 2: Subsistemas.....	84
3.3.4.3.	Nivel 3: Módulos.....	84
3.3.4.4.	Nivel 4: Rutinas.....	85
3.3.5.	Desarrollo de la aplicación informática.....	100
3.4.	Conclusiones.....	109
	Referencias bibliográficas.....	110

4.	Aplicación de la técnica de Imágenes hiperespectrales a la detección temprana de roya ( <i>Hemileia vastatrix Berkeley y Broome</i> ) en hojas de café arábica ( <i>Coffea arabica L.</i> ) var. <i>Typica</i> .....	115
4.1.	Introducción .....	116
4.2.	Planta de café .....	118
4.3.	Generalidades de la enfermedad por roya.....	120
4.4.	Escalas de medición del daño por roya .....	127
4.5.	Materiales y metodología.....	130
4.5.1.	Material biológico.....	130
4.5.2.	Sistema de imágenes hiperespectrales. ....	132
4.5.3.	Metodología .....	132
4.6.	Resultados y discusión.....	142
4.7.	Conclusiones.....	150
	Referencias bibliográficas.....	151
5.	Aplicación de la técnica de imágenes hiperespectrales en la detección de adulteración de queso fresco con harina de maíz .....	158
5.1.	Introducción .....	159
5.1.1.	Materiales y metodología.....	163
5.1.2.	Material biológico.....	163
5.1.3.	Procedimiento experimental.....	163
5.2.	Resultados y discusión.....	172
5.2.1.	Caracterización de muestras .....	172
5.2.2.	Adquisición y procesamiento de imágenes .....	174
5.2.3.	Modelado .....	176
5.2.4.	Aplicación del modelo .....	179
5.3.	Conclusiones.....	180
	Referencias bibliográficas.....	182

6.	Aplicaciones de la técnica de imágenes hiperespectrales a la detección de la calidad de carne de res .....	188
6.1.	Introducción .....	189
6.2.	Material y métodos .....	193
6.2.1.	Muestras biológicas.....	193
6.2.2.	Metodología .....	194
A.	Obtención de modelo de ajuste.....	195
A.1	Caracterización de las muestras.....	195
A.2	Extracción de descriptores de la norma japonesa de marmoleado .....	196
A.3	Digitalización de la norma japonesa de marmoleo de carne.....	198
A.4	Modelado de relación entre descriptores y clases .....	199
B.	Determinación de estándares mediante imágenes hiperespectrales .....	199
B.1	Adquisición y corrección de imagen hiperespectrales.....	200
B.2	Entrenamiento de clasificador .....	200
B.3	Segmentación y clasificación de píxeles.....	201
B.4	Determinación de descriptores y clasificación automática de la muestra.....	201
C.	Determinación de estándares mediante jueces.....	201
6.3.	Resultados y discusión.....	202
6.3.1.	Caracterización de las muestras .....	202
6.3.2.	Análisis de parámetros estadísticos de vetas de grasa en norma japonesa.....	204
6.3.3.	Extracción de información espectral.....	207
6.3.4.	Resultados de la clasificación de marmoleado de las muestras .....	210
6.4.	Conclusiones.....	212
	Referencias bibliográficas.....	214
7.	Anexos .....	219
	Figura A. 1 Guide Hyper_1 .....	220
	Figura A. 2 Guide entrenamiento Hoja .....	261

Figura A. 3 Guide entrenamiento Opciones .....	274
--	-----

## Nomenclatura\*

AdaBoost	Método de selección AdaBoost
AOAC	Asociación de químicos analíticos oficiales (Association of official analytical chemists)
ARI1	Reflectancia de antocianinas, índice 1 (Anthocyanin reflectance index 1)
ARI2	Reflectancia de antocianinas, índice 2 (Anthocyanin reflectance index 2)
ARVI	Índice de vegetación atmosféricamente resistente (Atmospherically resistant vegetative index)
BIL	Banda intercalada por línea (Band interleaved by line)
BIP	Banda intercalada por píxel (Band interleaved by pixel)
BPNN	Red neuronal con realimentación (Back propagation neural network)
BSQ	Banda secuenciada (Band Sequential)
CCA	Análisis de correlación canónica (Canonical correlation analysis)
CE	Conjunto de espectros
CE <sub>ma</sub>	Conjunto de espectros no anómalos
COVENIN	Comisión venezolana de normas industriales
CRI1	Reflectancia de carotinoides, índice 1 (Carotenoid reflectance index 1)
CRI2	Reflectancia de carotinoides, índice 2 (Carotenoid reflectance index 2)
DT	Árbol de decisiones (Decision tree)
DW	Discriminación por dominio de longitudes de onda (Domain for the discriminant wavelength)
ELM	Máquina de entrenamiento extremo (Extreme learning machine)
EVI	Índice vegetativo mejorado (Enhanced vegetative index)
FAO	Organización para la agricultura y los alimentos (Food and agricultural organization)
GDA	Análisis general discriminante (General discriminant analysis)
HDR	Reducción de alta dimensionalidad (High dimensionality reduction)
HSI	Imágenes hiperespectrales (Hyperspectral image)
IR	Rango de onda infrarrojo (1700 – 2700 nm)
KNN	K-vecino más próximo (k- Nearest neighbors)
LDA	Análisis de discriminante lineal (Linear discriminant Analysis)
MCARI	Índice modificado de reflectancia de absorción de clorofila (Modified chlorophyll absorption reflectance index)
MCUVE	Eliminación de variables por el método de Monte Carlo (Monte Carlo uninformative variable elimination)
MFFS	Selección de características multiclas con realimentación (Multiclass forward feature selection)
MNF	Fracción de ruido mínimo (Minimum noise fraction)
MPF	Alimentos mínimamente procesados (Minimally processed food)
MRENDVI	Vegetación normalizada en límite rojo (Modified red edge normalized vegetation index)
MRESR	Tasa límite modificada del límite rojo (Modified red edge simple ratio)
NB	Método Naïves Bayes
NDVI	Diferencia vegetativa normalizada (Normalized difference vegetative index)
NG	Selección de ondas No Gausiana
NIR	Rango del infrarrojo cercano (Near infrared)
NN	Red neuronal (Neural network)
OEEE	Oficina de estudios económicos y estadísticos
OIC	Organización internacional del café

PAFR	Porcentaje de area foliar con roya
PCA	Análisis de componentes principales (Principal component analysis)
PCR	Reaccion de la cadena de plolimerasa (Polymerase chain reaction)
PLSR	Regresión mínimos cuadrados parciales (Partial least square regression)
PRESS	Suma mínima predecible de los residuos al cuadrado (minimum predicted residual sum of squares)
PRI	Reflectancia fotoquímica (Photochemical reflectance)
PSRI	Reflectancia de senescencia vegetal (Plant senescence reflectance)
PWCD	Discriminación de clases en pares (Pair-Wise Class Discriminability)
R	Reflectancia de imagen hiperespectral en bruto
R <sub>c</sub>	Imagen hiperespectral corregida en reflectancia relativa
R <sub>D</sub>	Imagen de referencia en negro
RGB	Formato de imagen tricolor: Rojo, Verde y Azul (Red, green and blue format)
RMSECV	Error cuadrático medio de la validación cruzada (Root-mean-square error of cross-validation)
RMSEP	Error cuadrático medio de predicción (Root mean square error of prediction)
RNA	Red neuronal artificial
ROI	Región de interés (Region of interest)
R <sub>w</sub>	Imagen de referencia en blanco.
R <sub>λ</sub>	Vector de reflectancia a longitud de onda $\lambda$
R <sub>λ-dsv</sub>	Desviación estándar de reflectancia promedio a longitud de onda $\lambda$
R <sub>λ-p</sub>	Reflectancia promedio a longitud de onda $\lambda$
SAGARPA	Secretaría de agricultura, ganadería, desarrollo rural, pesca y alimentación
SENASA	Servicio nacional de sanidad agraria de Perú
SIPI	Estructura de pigmento no sensitivo (Structure insensitive pigment index)
SPA	Algoritmos de proyección sucesiva (Successive projections algorithm)
SPLSR	Regresión mínimos cuadrados parciales estandarizada (Standardised partial least square regression)
SPM	Mapeador de espectro angular (Spectral angle mapper)
SR	Tasa simple (Simple ratio index)
SVC	Sistemas de visión por computador
SVDD	Descripción soportada en vector de datos (Support vector data description)
SVM	Maquina soportada en vectores (Support vector machine)
SVR	Regresión soportada en vectores (Support vector regression)
TBRM	Método de ratio de dos bandas (Two band ratio method)
UTM	Universal transversal de mercator
VIS	Rango de onda visible (400 – 800 nm)
VREI1	Limite rojo Vogelmann, índice 1 (Vogelman red edge index 1)
VREI2	Limite rojo Vogelmann, índice 2 (Vogelman red edge index 2)
VREI3	Limite rojo Vogelmann, índice 3 (Vogelman red edge index 3)
WBI	Banda de agua (Water band index)
$\lambda_i$	Longitud de onda

\* En caso de proceder de una expresión en ingles esta acompaña a la descripción entre paréntesis

=====

**1. Aplicaciones de la técnica de imágenes hiperespectrales en la agricultura y procesos agroalimentarios**

=====

## **1.1. Introducción**

La calidad y seguridad de los alimentos están directamente relacionados con la salud de los consumidores y el progreso social, y por lo tanto son temas considerados importantes en todo el mundo. Existe así expectativa a través de la sociedad de que los alimentos suministrados para el consumo humano sean seguros y nutritivos (Tao, Peng, Gomes, Chao y Qin, 2015), esto requiere el desarrollo e introducción de una adecuada legislación e inspección que garanticen la seguridad alimentaria (Ariana y Lu, 2010).

Dentro de los métodos de inspección actualmente usados, la inspección visual es aún ampliamente utilizada, pese a ser laboriosa, tediosa y de carácter subjetivo. Otros métodos de amplio uso son los métodos químicos analíticos, espectroscópicos y cromatográficos, cuya desventaja radica en ser métodos destructivos, demandan mucho tiempo, no manejan gran número de muestras y son costosos (Du y Sun, 2004; Lu y Ariana, 2013).

En este sentido, el desarrollo de métodos de inspección eficientes, no destructivos, rápidos y de bajo costo es importante para la industria alimentaria, a fin de garantizar la seguridad y trazabilidad de la

---

producción (Wu y Sun, 2013a). En años recientes se han dedicado muchos esfuerzos a desarrollar técnicas de análisis no destructivas; a fin de medir mediante éstas tanto propiedades internas como externas, basadas en diversos principios físicos, procedimientos e instrumentos. Algunos ejemplos serían: las técnicas de ultrasonido, escaneo axial computerizado, visión por computador, espectroscopía e imágenes hiperespectrales (Xiong, Sun, Zeng y Xie, 2014). De entre éstas, las tecnologías de detección óptica y, especialmente, las imágenes hiperespectrales, han sido y vienen siendo investigadas como potencial herramienta para el análisis no destructivo de la calidad y seguridad de productos agroalimentarios tal como lo demuestran los trabajos de Cheng y col., (2015), Dai, Cheng, Sun y Zeng, (2014), Fernandes y col. (2015), Fu y col. (2014), Lu y Ariana (2013), Rivera y col.(2014), Siedliska, Baranowski y Mazurek (2014), entre otros.

De entre los autores que han revisado las aplicaciones de la tecnología de imágenes hiperespectrales, la revisión de Zhang y col. (2014), las generalidades de la visión por computador y, como un punto de ésta, la tecnología de imágenes hiperespectrales y sus aplicaciones. Otra revisión que aborda la tecnología de imágenes hiperespectrales y sus aplicaciones es la de Wu y Sun (2013a, 2013b), la cual explica las generalidades de

los equipos y métodos utilizados así como las aplicaciones en un amplio espectro de productos agroalimentarios. Por otro lado, existen algunas revisiones menos específicas como la realizada por Magwaza y Opara (2015) la cual aborda diferentes métodos para la determinación del contenido de azúcares en productos hortofrutícolas dentro de los cuales hace referencia a la tecnología de imágenes hiperespectrales.

Por la importancia de esta técnica y a fin de eslabonar los recientes avances que harán posible su aplicación y desarrollo futuro, se ha elaborado la revisión que conforma este capítulo, la cual se ocupa de los aspectos generales y conceptuales de las imágenes hiperespectrales, y recopila información actualizada sobre estudios de la aplicación de esta tecnología en la evaluación de la calidad y seguridad de productos agroalimentarios, centrandos éstos en productos de la agricultura y actividades postcosecha.

## **1.2. Aspectos generales**

Originalmente, las imágenes hiperespectrales fueron desarrolladas para aplicaciones en control/análisis remoto, las cuales utilizan imágenes satelitales de la tierra, luna y planetas, pero han encontrado potencial en

otros campos como la agricultura, farmacéutica y la industria alimentaria (Elmasry y Sun, 2010; Fu y col., 2014; Xiong y col., 2014).

Para la correcta interpretación y uso de ésta técnica es importante una buena comprensión de los conceptos y principios que la rigen, por lo que, a continuación se exponen algunos conceptos fundamentales de la técnica de imágenes hiperespectrales.

### **1.3. Concepto de imagen hiperespectral**

La tecnología de imágenes hiperespectrales (HSI) combina las ventajas de la visión por ordenador tradicional y la espectroscopía; esta tecnología permite medir simultáneamente la variación espacial y espectral de una muestra (Dai y col., 2014; ElMasry, Sun y Allen, 2013). Dicha variación espectral es producto de la interacción de la radiación de la materia, para cientos de longitudes de ondas y puntos de muestreo simultáneamente, y puede ser cuantificada por reflectancia, la cual es definida como el porcentaje de luz emitida por una muestra con relación a la luz total que incide en ella (Fernandes y col., 2013; Qin, Chao, Kim, Lu y Burks, 2013).

La tecnología de imágenes hiperespectrales permite adquirir imágenes digitales con una gran cantidad de canales espectrales muy cercanos entre sí, incluyendo algunas regiones no detectables por el ojo humano como el ultravioleta, infrarrojo cercano e infrarrojo (Simko, Jimenez-Berni y Furbank, 2015), y obteniendo para cada porción de la escena o píxel, una firma espectral característica de cada material; siendo difícil que distintas combinaciones espectrales, aun siendo muy parecidas, generen la misma salida (Cho y col., 2013; Rivera y col., 2014; Sengupta y Lee, 2014). En la Figura 1.1 se muestran 400 espectros obtenidos a partir de una región de interés (ROI) cuadrada de 20 x 20 píxeles de una hoja de café variedad típica (*Coffea arabica var. typica*); la cual muestra que los espectros en esta ROI, aun con tendencias similares, presentan claras diferencias en sus valores de reflectancia para el intervalo entre 200 y 800 nm.

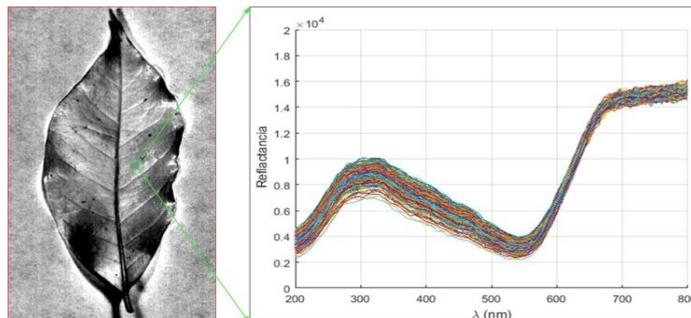


Figura 1.1 Espectros de reflectancia relativa de una ROI cuadrada en una hoja de café variedad típica (*Coffea arabica var. typica*)

A partir de las diferencias en los espectros es posible distinguir en las muestras materiales, sustancias y objetos que mediante los SVC pueden verse iguales e indistinguibles (Gómez, 2010; Rivera y col., 2014; Sengupta y Lee, 2014). Como ejemplo de lo antes descrito se muestran, en la Figura 1.2, una imagen en formato RGB y cuatro en formato escala de grises en el rango de 200 a 800 nm de una hoja de café variedad típica (*Coffea arabica*). En estas se observan áreas infectadas con *Hemileia vastatrix* Berkeley y Broome las cuales son distinguibles visualmente principalmente a longitudes de onda entre 400 y 600 nm.

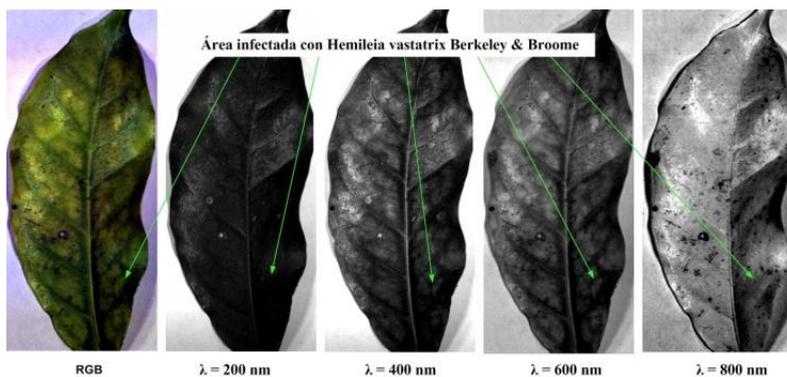


Figura 1.2 Imágenes RGB y en formato de grises de café variedad típica infectadas con *Hemileia vastatrix* Berkeley y Broome

En cuanto a la organización de la información en una imagen hiperespectral, la Figura 1.3 muestra una representación esquemática de una imagen hiperespectral. En ésta, la información se organiza en una matriz tridimensional (denominada hipercubo), en cuyas dos primeras

dimensiones o ejes se almacena, mediante los conceptos de línea (X) y muestra (Y), la información espacial y en la tercera dimensión ( $\lambda$ ) la información espectral (Cho y col., 2013; Paz, 2009; Chang y Du, 2004; Xiong y col., 2014). Por tanto, un píxel situado en la coordenada (x, y) es un vector de bandas en el que cada elemento del vector corresponde a una de las diferentes longitudes de onda empleadas en el proceso de adquisición de la imagen y puede representarse en coordenadas longitud de onda ( $\lambda$ ) vs reflectancia o intensidad.

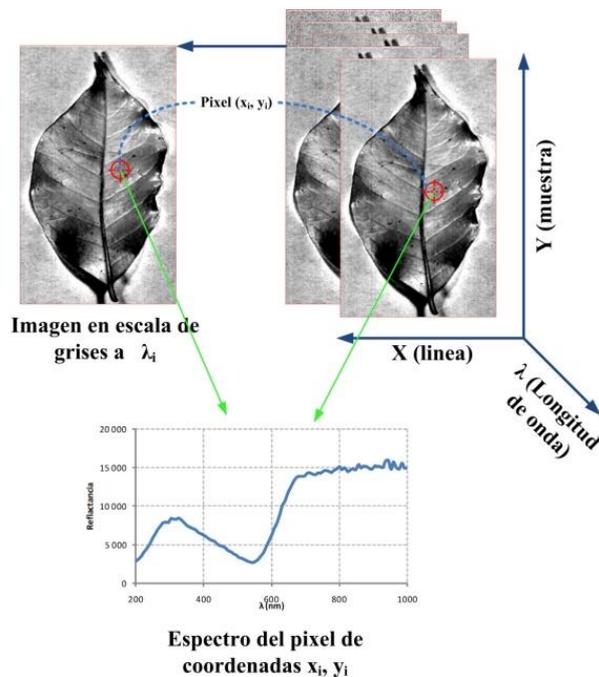


Figura 1.3 Estructura esquemática de una imagen hiperespectral, ejes espaciales X, Y y  $\lambda$  (A partir de Cho y col., 2013; Gowen, O'Donnell, Cullen, Downey y Frías, 2007; Xiong, Sun, Zeng y Xie, 2014)

En cuanto al análisis de una imagen hiperespectral, éste se podría resumir en la Figura 1.4, donde se ilustra el procedimiento de adquisición y análisis de imágenes hiperespectrales, el cual se puede dividir en tres etapas: a) Adquisición y preprocesado, de acuerdo a los métodos de adquisición detallados en el apartado 1.2; b) Caracterización de muestras, etapa en la que se determina el nivel de los parámetros físicos, químicos, microbiológicos y sensoriales que serán utilizados en la última etapa; c) Modelización, en la cual se utilizan técnicas de análisis estadístico multivariable para correlacionar estos parámetros con la información espectral de la etapa b (Du y Sun, 2004; Elmasry y Sun, 2010; Liu, Sun y Zen, 2013; Sun, 2010).

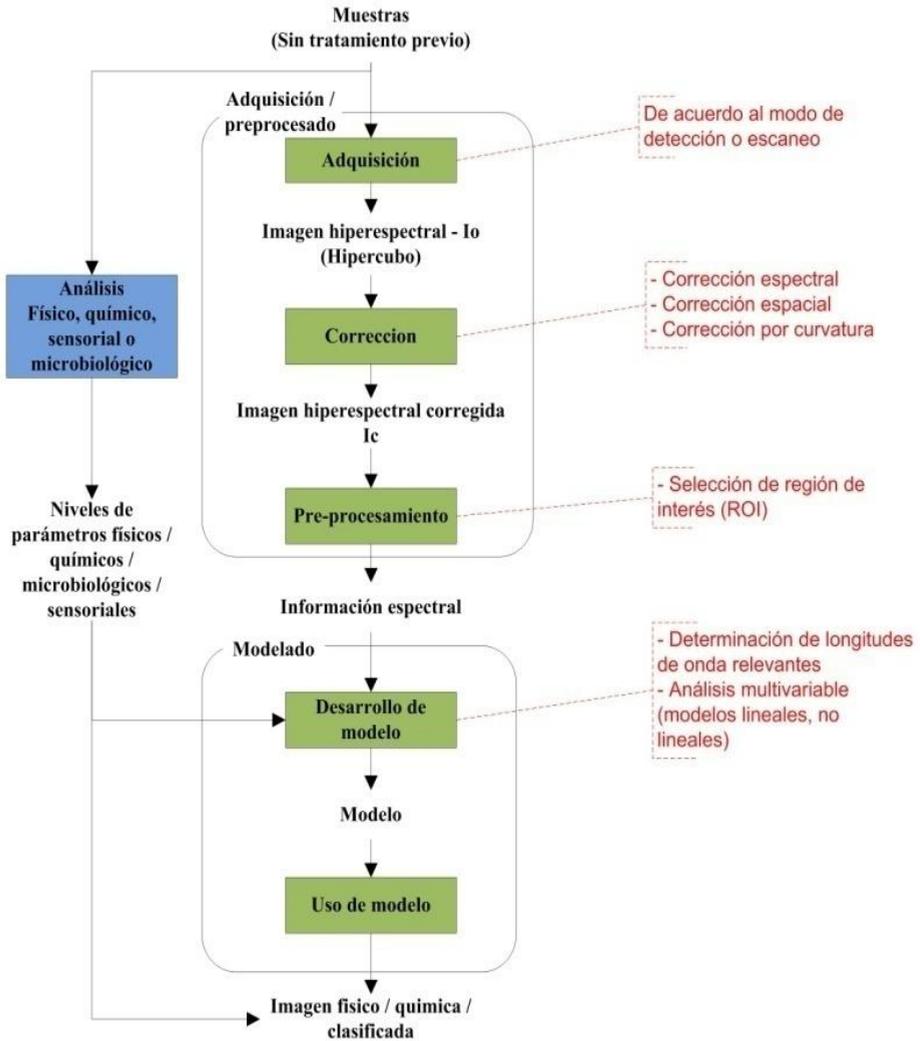


Figura 1.4 Pasos a seguir en el análisis de imágenes hiperespectrales (A partir de Liu, Sun y Zen, 2013; Liu y col., 2013; Sun, 2010)

En este punto es conveniente aclarar que frecuentemente se encuentran mezclas a nivel de subpíxel. De este modo, los píxeles de una imagen pueden clasificarse en dos categorías: píxeles puros (en el que sólo hay un tipo de material) y píxeles mezcla (en que cohabitan diferentes

materiales), siendo estos últimos los que constituye la mayor parte de los píxeles en tejidos alimentarios (Chang y Du, 2004).

### **1.3.1. Avances en sistemas de adquisición de imágenes hiperespectrales**

Los sistemas de imagen hiperespectral se componen principalmente de dos partes: hardware y software. El papel de hardware es la obtención de las imágenes, mientras que el software permite procesar las imágenes con el fin de extraer información de la imagen útil para predecir los atributos de calidad de los productos (Xiong y col., 2014). A continuación se brindan mayores detalles de estas partes:

#### **a) Hardware**

Los avances logrados en la aplicación de esta tecnología han conllevado a mejoras en la velocidad y costo del hardware; sin embargo, los elementos típicos, esquematizados en la Figura 1.5, siguen siendo los mismos por los últimos veinte años y sólo difieren en la disposición de los mismos (Gowen y col., 2007; Zhang y col., 2014).

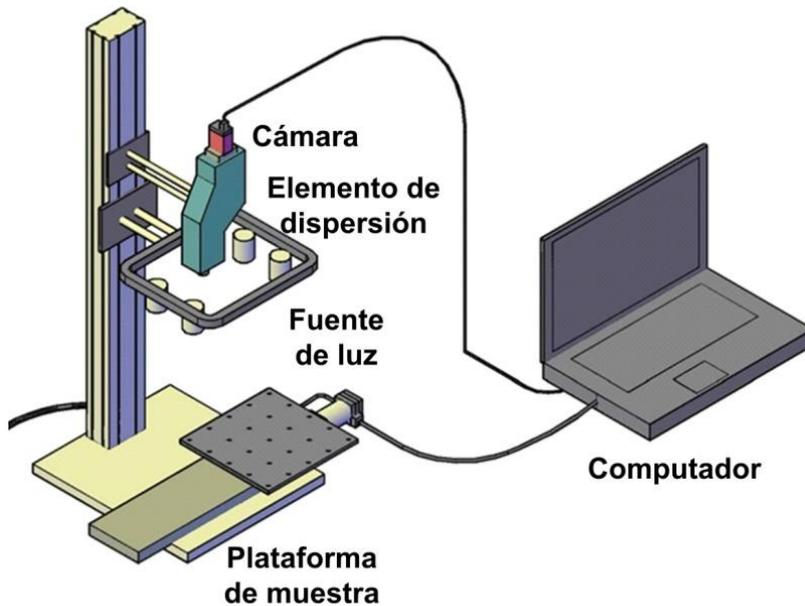


Figura 1.5 Esquema de un sistema de adquisición de imágenes hiperespectrales

Estos elementos son:

- a) Fuentes de luz. Generan luz para iluminar la muestra y son una parte esencial de los sistemas de inspección óptica. Las fuentes de luz empleadas en los sistemas de adquisición de imágenes hiperespectrales incluyen: lámparas halógenas (fuente de iluminación de banda ancha usados en longitudes de onda visible (VIS) y el infrarrojo cercano (NIR); generalmente son de tungsteno), diodos emisores de luz – LED (elementos emisores de luz, pequeños, de bajo coste, respuesta rápida, larga vida y bajo consumo de energía) y

---

láseres (fuentes de luz monocromáticas principalmente usados para excitar los electrones en la muestra). Las longitudes de onda de uso en onda corta recorren desde el ultravioleta al infrarrojo cercano y en onda larga, desde el infrarrojo cercano a infrarrojo medio (Ariana y Lu, 2008; Wu y Sun, 2013a).

- b) Cámara. La función de este dispositivo es cuantificar la luz adquirida mediante la conversión de fotones incidentes en electrones a través de un circuito integrado el cual contiene un número de condensadores dispuestos en un arreglo matricial. Este circuito se denomina dispositivo de carga acoplada -CCD (Coupled Charged Device). Una alternativa a los CCDs son los semiconductores complementarios de oxido metálico -CMOS (Complementary Metal Oxide Semiconductor). Ambos convierten la energía de radiación a señal eléctrica y los materiales usados para la fabricación de estos detectores son el silicio, arseniuro de galio y el telurio de galio (Gowen y col., 2007; Wu y Sun, 2013a; Xiong y col., 2014).
- c) Elemento de dispersión. Tienen la función de dispersar, en bandas, las diferentes longitudes de onda que componen la luz provista por el sistema de iluminación. Dentro de éstos tenemos los

espectrofotómetros de imágenes, filtros sintonizables acústico-ópticos- AOTF (Acoustic-Optic Tunable Filters) y los filtros sintonizables de cristal líquido- LCTF (Liquid Crystal Tunable Filter) (Gowen y col., 2007; Xiong y col., 2014); las diferencias entre estos dispositivos se muestran en la Tabla 1.1.

Tabla 1.1. Diferencias entre dispositivos de dispersión

<b>Dispositivos</b>	<b>Imagen hiperespectral formada</b>	<b>Desplazamiento de muestra</b>
Espectrofotómetro de imagen	– Imagen espectral de un punto o línea de la escena	– Requiere desplazamiento
Filtros sintonizables (AOTF – LCTF)	– Imagen monocromática completa de cada banda	– No requiere desplazamiento de muestra

Fuente: adaptado de Sun (2010)

d) Plataforma de muestra. De acuerdo a la Tabla 1.1, en función del dispositivo de dispersión es posible que se requiera de una plataforma que desplace a la muestra misma a una velocidad constante mientras se realiza la captura de la escena por parte de la cámara (Gowen y col., 2007).

## b) Software

El software para estos sistemas incluye las tareas de procesamiento digital de imágenes hiperespectrales (Figura 1.4), las cuales incluyen: Corrección (espectral, espacial, curvatura), selección de ROIs, reducción de dimensionalidad y modelización de relaciones (Wu y Sun, 2013b). En la Tabla 1.2 se comentan algunos programas que, individualmente o combinados, han sido empleados como herramientas informáticas para el procesamiento y análisis de imágenes hiperespectrales.

Tabla 1.2. Softwares empleados para el procesamiento de imágenes hiperespectrales

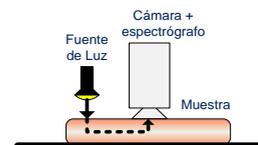
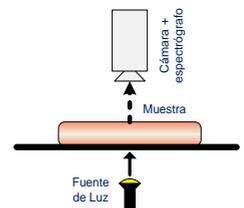
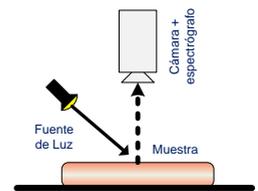
Software	Desarrollador	Aplicación principal	Fuentes
Matlab	The Math-Works Inc., Natick	<ul style="list-style-type: none"> <li>- Reducción de dimensionalidad</li> <li>- Desarrollo de programas de análisis</li> <li>- Desarrollo de modelos.</li> <li>- Visualización de imágenes.</li> </ul>	Mishra y col. (2016) Barbedo, Tibola y Fernandes (2015) Everard, Kim y Lee (2014)
ENVI	Visualizing Images, desarrollado por Research Systems Inc.	<ul style="list-style-type: none"> <li>- Selección de ROIs.</li> <li>- Visualización de imágenes hiperespectrales.</li> </ul>	Fernandes y col. (2015) Zhang y col. (2015)
Unscrambler	CAMO Software	<ul style="list-style-type: none"> <li>- Reducción de dimensionalidad</li> <li>- Desarrollo de modelos</li> </ul>	Deng, Xu, Li, Li y He (2013) Zhang, Liu, He y Gong (2013)
JMP	SAS Institute Inc.	<ul style="list-style-type: none"> <li>- Reducción de dimensionalidad</li> <li>- Desarrollo de modelos</li> </ul>	Simko, Jimenez-Berni y Furbank (2015) Rud, Shoshany y Alchanatis (2013)
R	Development Core Team	<ul style="list-style-type: none"> <li>- Reducción de dimensionalidad</li> <li>- Desarrollo de modelos</li> </ul>	Abdel y col. (2014)

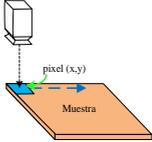
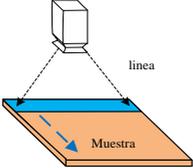
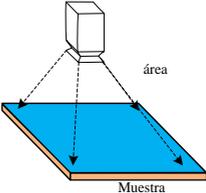
### 1.3.2. Modos de detección y escaneo de imágenes hiperespectrales

Un hipercubo se construye de acuerdo a los diferentes modos de detección y escaneo (Tabla 1.3). Dependiendo éstos a su vez de la disposición y conformación de los elementos que constituyen el sistema de adquisición (Gowen y col., 2007; Xiong y col., 2014; Zhang y col., 2014).

Tabla 1.3 Modos de detección y escaneo de imágenes hiperespectrales

Modo de detección	Esquema
Reflectancia	<ul style="list-style-type: none"> <li>- El sensor captura la luz reflejada desde el mismo lado en que la muestra es iluminada.</li> <li>- Modo usado para la obtención de características de calidad externos (tamaño, forma, color, textura superficial y defectos).</li> </ul>
Transmitancia	<ul style="list-style-type: none"> <li>- El sensor capta la luz transmitida a través de la muestra que lleva información interna</li> <li>- Se utiliza generalmente para determinar la concentración de los componentes internos y defectos internos de objetos relativamente transparentes tales como pescado, frutas y verduras</li> </ul>
Interactancia	<ul style="list-style-type: none"> <li>- La fuente de luz y el sensor están situados en el mismo lado de la muestra y paralelos entre sí.</li> <li>- Este modo puede detectar información más profunda de la muestra y tiene menos efectos de superficie en comparación con el modo de reflectancia.</li> </ul>



<b>Modo de escaneo</b>		
– Punto	<p>La adquisición de espectros se realiza a través de una serie de posiciones espectrales adyacentes y requiere el movimiento relativo de la muestra con respecto al sensor. El formato de salida es *.BIP (Banda intercalada por pixel).</p>	
– Línea	<p>Este modo graba los espectros de cada pixel en una línea de la muestra. El hiper cubo es guardado en formato *. BIL (Banda intercalada por línea).</p>	
– Área	<p>El sensor adquiere la información espectral de una área rectangular; el sensor utilizado es del tipo filtro sintonizable. El formato utilizado es *.BSQ (Banda secuencial).</p>	

Fuente: a partir de Gowen y col., (2007); Zhang y col., (2014)

### 1.3.3. Ventajas y desventajas de la técnica de imágenes hiperespectrales

Según ElMasry y col. (2007) y Wu y Sun (2013) las principales ventajas y desventajas del uso de la técnica de imágenes hiperespectrales y análisis de imágenes en la industria agroalimentaria, en relación a los métodos tradicionales son los que se detallan en la Tabla 1.4.

Tabla 1.4. Ventajas y desventajas de la aplicación de la técnica de imágenes hiperespectrales a la industria alimentaria

Ventajas	Desventajas
– Evaluación libre de químicos,	– Requerimiento de gran velocidad del hardware para mejorar la adquisición y el análisis de datos,
– Mínima preparación de la muestra,	– Necesidad de calibración precisa y modelos robustos,
– Ahorro de mano de obra, tiempo, reactivo, tratamientos de residuos,	– Menores límites de detección en comparación a los métodos de análisis químicos,
– No invasión, ni destrucción de la muestra,	– No es aplicable muestras líquidas u homogéneas,
– Aplicaciones para análisis cualitativos y cuantitativos,	– Limitada penetración de la luz,
– Delimitación múltiple de diferentes componentes dentro de una muestra en forma simultánea,	– Efecto de calentamiento, debido a la luz emitida durante el proceso de obtención de las imágenes: este es potenciado por el espectro de absorción del agua.
– Análisis relativamente rápido,	
– Visualización simultánea de la distribución espacial de diferentes parámetros de calidad,	
– Almacena abundante información para la evaluación de la calidad y seguridad alimentaria.	

Fuente: a partir de Barbedo, Tibola y Fernandes (2015); Fernandes y col. (2015); Xiong, Sun, Zeng y Xie (2014)

#### 1.4. Aplicaciones de los sistemas de imágenes hiperespectrales

Según se ha comentado anteriormente, los sistemas de imágenes hiperespectrales surgieron en investigaciones relacionadas con la observación de la tierra (Lilles, Kiefer y Chipman 2014), y se

---

extendieron posteriormente a otros campos de la ciencia, entre los que se encuentra la tecnología alimentaria (Wu y Sun, 2013a). En relación a esta última, se han desarrollado trabajos en un amplio espectro de aplicaciones tales como: predicción de terneza en carne de res (He, Wu y Sun, 2014; Naganathan y col., 2015a; 2015b), detección de infección por mosca de la fruta (Lu y Ariana, 2013), predicción de composición en diversos alimentos (Everard y col., 2014; Fernandes y col., 2015), detección de defectos y daños (ElMasry, Wang y Vigneault, 2009; Gómez, 2010; Zhang y col., 2015), detección de contaminantes en leche (Fu y col., 2014) entre otras. Otros campos en los cuales vienen desarrollándose aplicaciones de la técnica de imágenes hiperespectrales es la agricultura, en áreas como en el manejo poscosecha de frutas y hortalizas, evaluando procesos de deterioro durante almacenamiento, evaluación del estado de madurez, seguimiento de cambios composicionales y contaminación (Tiwari, Slaughter y Cantwell, 2013; Rady, Guyer, Kirk y Donis-González, 2014; Slaughter, 2009; Zhou, Kaneko, Tanaka, Kayamori y Shimizu, 2015). En los siguientes párrafos se comentará con más detalle algunas de las aplicaciones más recientes.

## 1.5. En agricultura y control de semillas

En la agricultura y el control de las semillas se han venido desarrollando aplicaciones de la tecnología de imágenes hiperespectrales en diferentes aspectos, tales como la evaluación del efecto de los niveles de salinidad en los suelos y la vegetación, la detección temprana de plagas y enfermedades, y la clasificación de la calidad. Algunos de los trabajos más recientes se listan en la Tabla 1.5.

Tabla 1.5. Aplicaciones de la tecnología de imágenes hiperespectrales a la agricultura y semillas agroalimentarias

Material	Muestra	Objetivo	Equipo / modo	$\lambda$ (nm)	Coefficiente* (CR - CE)	Fuente
Cultivo	Campo de cultivo	Detección de brotes	HSI / R	400 – 1000	CE = 87 %	Wouters, Ketelaere, Deckers, Baerdemaeker y Saeys (2015)
	Campos de cultivo	Comparación de métodos	ESR / R	350 -2500 1000-2500	CR <sub>PLSR</sub> = 0.64 – 0.54 CR <sub>SPLSR</sub> = 0.94 – 0.92	Abdel y col. (2014)
	Campos de cultivo	Detección de estrés	ESR -HSI / R	470 – 850 420 – 560	CE = 62 %	Rud y col. (2013)
Semillas agroalimentarias	Maíz	Detección de contaminación	HSI / R	528 – 1785	CE = 91 % CR <sub>SVM</sub> = 79.0 %	Barbedo, Tibola, y Fernandes (2015)
	Granos diversos	Detección de contaminación	HSI / R	1000- 1600	CR <sub>NB</sub> = 60.9 % CR <sub>K-NN</sub> = 90.1 %	Ravikanth, Singh, Jayas y White (2015)
	Maíz	Detección de contaminación	HSI / R	1000 - 2500	CE = 83.3 % - 88.88 %	Wang y col. (2015)
	Semillas de sésamo	Clasificación	HSI / R	325 – 1075	CR <sub>SPA-SVM</sub> = 0.83 - 0.95 CR <sub>SVM-MFSS</sub> = 0.83 - 1.00	Deng, Xu, Li, Li y He (2013)
	Granos	Clasificación	HSI / R	1013 -1650	CR = 91.0 % – 99.0 %	Serranti, Cesare y Bonifazi (2012)
	Vainas de soya	Detección de infestación	HSI / T	400 - 1000	CR = 95.6 %	Huang, Wan, Zhang y Zhu (2013)

\* Coeficiente de correlación (CR); Coeficiente de exactitud (CE)

\*\* Sistema de adquisición de imágenes hiperespectrales (HSI); Espectroradiómetro (ESR); Reflectancia (R); Transmitancia (T)

---

Las aplicaciones, realizadas en cultivos o semillas agroalimentarias, han usado como muestras de estudio campos de cultivo o granos, tanto secos como en vaina, respectivamente; siendo los objetivos generales, para el caso de cultivos, seguimiento del proceso vegetativo (Wouters y col., 2015), evaluación del efecto de salinidad en el estrés hídrico (Rud y col., 2013) y, aunque orientada al análisis estadístico, la comparación de dos métodos de modelado (PLSR y SPLSR) en la exactitud del modelo de la relación entre las fuentes hídricas y el rendimiento del cultivar (Abdel y col., 2014). En cuanto a las aplicaciones en semillas agroalimentarias, los objetivos se han concentrado principalmente en la determinación de la contaminación (Barbedo y col., 2015; Ravikanth y col., 2015; Wang y col., 2015), en segundo lugar en clasificación (Deng y col., 2013; Serranti y col., 2012) y por último en la detección de infestación por insectos (Huang y col., 2013); cubriendo en ambos casos el rango UV, VIS-NIR, NIR.

En los trabajos revisados se utilizan principalmente sistemas de adquisición de imágenes hiperespectrales y modo de reflectancia; salvo dos que utilizaron espectroradiómetros y uno el modo de transmitancia, para la detección de infestación. Esto se debe a que las características a medir se encuentran en la superficie del objeto, para la cual los sistemas

---

de reflectancia son más aptos (Zhang y col., 2014; Xiong y col., 2014). Los métodos de análisis han sido diversos, basado en regresiones lineales múltiples (PLSR, SPLSR), métodos no lineales (K-NN, RNA, NB) y otros métodos (CCA, SVM, SVDD, MFSS). Para alimentar los modelos se han usado valores de reflectancia estandarizada o índices espectrales como el GIR (Green and indigo ratio) usado por Rud y col. (2013). Estos índices espectrales permitieron detectar y correlacionar las diferencias entre las reflectanciasfoliares y los niveles de la salinidad, resultados similares a los reportados por Lara y col. (2013) quien trabajando con lechugas “baby” relacionaron los cambios en la absorción luminosa de la clorofila a longitudes de onda de 550, 680 y 720 nm y la salinidad en el rango entre 50 y 150 mM NaCl.

Las investigaciones en estos campos refieren resultados exitosos con elevados valores de correlación y exactitud en la mayoría de los casos. Los mejores resultados se alcanzaron en semillas, alcanzándose hasta el 99% de éxito en la clasificación de la calidad de granos (Serranti y col., 2012); en detección de infestación por insectos 95% (Huang y col., 2013) y determinación de la contaminación, hasta el 91% (Barbedo y col., 2015). Resultados algo menos exitosos se lograron en el caso de cultivos, donde los mejores resultados se lograron en la detección de

---

brotos 87% (Wouters y col., 2015). Es interesante puntualizar que los resultados obtenidos son dependientes del análisis estadístico aplicado, como bien muestran Abdel y col. (2014); Deng, Xu, Li, Li y He (2013) y Ravikanth, Singh, Jayas y White (2015), quienes, evaluando diferentes técnicas de modelización de relaciones, lograron incrementar en promedio el coeficiente de correlación en un 57%.

### **1.5.1. En el procesamiento postcosecha**

Los sistemas de visión hiperespectral han sido aplicados en el procesamiento postcosecha de productos hortofrutícolas para tareas de inspección de frutas en fresco; donde la inspección individual, realizada en la empacadora, es principalmente visual, tediosa, subjetiva y de alto costo (Gómez, 2010). En este sentido la tecnología de imágenes hiperespectrales se vienen usando en la detección de podredumbre en cítricos y legumbres (Gómez, 2010; Gómez-Sanchis y col., 2013; Huang y col., 2013; Lorente y col., 2013; Simko y col., 2015); detección de madurez en mango y melocotón (García y col., 2011; Slaughter, 2009); evaluación de la calidad en mango, pepinos, manzanas (Ariana y Lu, 2008; Mendoza, Lu y Cen, 2014; Mizushima y Lu, 2013; Vélez-Rivera y col., 2013); detección de golpes en manzanas y cítricos (Lee y col.,

---

2014 Qin, Burks, Ritenour, y Bonn, 2009; Rivera y col., 2014; Xing y De Baerdemaeker, 2005). Estas investigaciones, por la alta complejidad y multicolinealidad de la información contenida en cada imagen hiperespectral (Cho y col., 2013; Liu y col., 2013; Wu y Sun, 2013b) han usado valores de reflectancia, previa selección de longitudes de onda relevantes (Fernandes y col., 2015; Rodríguez-Pulido y col., 2013; Yang, Sun, Pu, Wang y Zhu, 2015), o el uso de descriptores, ratios (Kimiya, Sivertsen y Heia, 2013; Simko y col., 2015).

En este campo se ha enfatizado la estimación de la calidad de las frutas previa a la cosecha, a fin de establecer la fecha óptima de recolección, así como en la evaluación de los cambios en la calidad posterior a la cosecha, determinando el tratamiento postcosecha más adecuado. Dichas evaluaciones, tal y como se presenta en la Tabla 1.6 se centraron en parámetros como: firmeza, color, contenido de sólidos solubles, presencia y distribución de pigmentos entre otros.

Tabla 1.6 Aplicaciones de tecnología de imágenes hiperespectrales a procesamiento postcosecha

Objetivo	Muestra	Parámetros analizados	Análisis	Equipo / modo	$\lambda$ (nm)	Coefficiente* (CR - CE)	Fuente
Predicción de composición	Uvas	pH °Brix Contenido de antocianina	PCA, BPNN	HSI / R	380 – 2018	CR <sub>pH</sub> = 0.82 CR <sub>°Brix</sub> = 0.89 CR <sub>Antocianins</sub> = 0.87	Fernandes y col. (2015)
	Lychee	Contenido de antocianinas	SPA, SVR, NN	HSI / R	308 – 1105	CR = 0.891 - 0.872	Yang y col. (2015)
	Hojas	Contenido de: Fosforo (P) Potasio (K) Nitrógeno (N)	PLSR, SVM	HSI / R	380 - 1030	CR <sub>N</sub> = 0.882 CR <sub>P</sub> = 0.710 CR <sub>K</sub> = 0.746	Zhang y col. (2013)
Predicción de composición Predicción de propiedades mecánicas	Arándanos	°Brix Firmesa Contenido de:	PLSR	HSI / R	500 - 1000	CR <sub>°Brix</sub> = 0.69–0.79 CR <sub>Firmesa</sub> = 0.87 CR <sub>glucosa, R</sub> = 0.90 - 0.95	Leiva-Valenzuela, Lu y Aguilera (2013)
	Papas	Glucosa Sucrosa °Brix	PLSR	HSI / I HSI / T HSI / R	446-1125	CR <sub>°Brix, I</sub> = 0.55 CR <sub>sucrosa, I</sub> = 0.81 CR <sub>sucrosa, T</sub> = 0.63	Rady y col. (2014)
Predicción de contaminación	Lechuga	UFC	TRESHOLD	HSI / R	400 - 700	--- CE <sub>V,PLSDA</sub> = [83-100] CE <sub>V,TBRM</sub> = [61 - 100]	Lee y col. (2014)
	Espinacas	UFC	PLSD, TBRM	HSI (V) / R	464 - 800	CE <sub>UV,PLSDA</sub> = [87-100]	Everard y col. (2014)
				HSI (UV) / R	464 - 800	CE <sub>UV,TBRM</sub> = [74 - 100]	
				HSI (NIR) / R	456 - 950	CE <sub>NIR,PLSDA</sub> = [15-100] CE <sub>NIR,TBRM</sub> = [0 - 100]	
Tomates	UFC	TRESHOLD	HSI / R	460 - 800	CE = 86 - 95 %	Yang y col. (2014)	

Determinación de calidad	Arándano	Estado de madurez	PWCD, HDR, NG KNN, SVM, AdaBoost	HSI / R	398-1010	CE > 88%	Yang, Lee y Gader (2014)
	Lechugas	Senescencia	PLSR, Student t-test	HSI / R	380 - 1012	CE = 96.7 - 96.9 %	Simko y col. (2015)
	Melocotón	Defectos	MCUVE, SPA, DW, MNF	HSI / R	400 - 1000	CE = 87.5 - 96.7 %	Zhang y col. (2015)
	Tomates	Defectos Variedad	PCA, ANOVA	HSI / R	400 - 700	CE = 99.1 %	Cho y col. (2013)
	Semillas de vid	Estado de madurez	PCA, GDA, PLSR	HSI / R	914-1715	CR = 0.91 -0.94	Rodríguez-Pulido y col., (2013)
	Liche	Nivel de pardeamiento	PLSR, SPA, BPNN, SVR	HSI / R	400 - 1000	CR = 0.946	Yang y col. (2015)
Detección de daño mecánico	Peras	---	ANOVA	HSI / R	959 -1650	CE = 92%,	Lee y col. (2014)
	Mango	---	LDA, KNN, NB, DT, ELM	HSI / R	650- 1080	CE = 91.4 - 97.9 %	Rivera y col. (2014)
Detección de daño por insectos	Pepinos	Infestación	PLSDA	HSI / R HSI / T	450-740 740-1000	CR <sub>R</sub> = 82% - 88% CR <sub>T</sub> = 88 - 93%	Lu y Ariana (2013)
Evaluación método de segmentación	Soya	---	SVDD	HSI / T	400 - 1000	CE = 98.8 %	Ma, Huang, Yang y Zhu (2014)

\* Coeficiente de correlación (CR); Coeficiente de exactitud (CE)

\*\* Sistema de adquisición de imágenes hiperespectrales (HSI); Espectroradiómetro (ESR); Reflectancia (R); Transmitancia (T)

---

En la Tabla 1.6 se mencionan algunos recientes estudios orientados a desarrollar metodologías, basadas en tecnologías espectrales, con las cuales determinar los cambios generados durante el proceso de maduración de los vegetales. Estos cambios se deben a modificaciones propias de los procesos metabólicos de maduración como la degradación de la clorofila durante el proceso de maduración y senescencia (Heaton y Marangoni, 1996; Simko y col., 2015); concordante con resultados como el de Lleó y col. (2011), el cual mostro que las bandas de absorción de la clorofila y la del agua están estrechamente relacionadas con el estado de madurez y la firmeza en melocotones. Esta presencia de clorofila, así como otros pigmentos, permite el desarrollo de métodos de clasificación de la madurez como los reportados por Simko, Jimenez-Berni, y Furbank (2015); Yang, Lee y Gader (2014); Vélez-Rivera y col. (2013), quienes utilizando imágenes hiperespectrales lograron eficiencias de hasta 100% en la clasificación de tres fases de madurez.

En cuanto a los sistemas y modos de detección utilizados se observa que se ha utilizado principalmente HSI y el modo de reflectancia; salvo en el caso de los trabajos de Ariana y Lu (2008) y Ma, Huang, Yang y Zhu (2014) quienes utilizaron el modo de transmisión para la detección de la infestación por insectos en pepinos y soya respectivamente o el de Rady,

---

Guyer, Kirk y Donis-González (2014) quienes compararon los modos de detección para la predicción de la composición de papas. Esto es coincidente con los trabajos revisados en la sección 2.1; mostrando que los modos de transmitancia e interactancia, se usan con la finalidad de obtener información del interior del material (Zhenjie Xiong y col., 2014), en algunos casos incrementando los coeficientes de exactitud o correlación de los modelos reportados como en el trabajo de Lu y Ariana (2013) el cual reporto un incremento en la exactitud de la detección de infestación por mosca de la fruta de 88 % a 93 %. Por otro lado; la obtención de imágenes por el modo de dispersión, aún sin ser reportado como un modo propiamente dicho, se ha utilizado en la predicción de la firmeza de manzana, banano, fresas, arándanos, pera y durazno (Ariana y Lu, 2010; Lu y Peng, 2006; Peng y Lu, 2008) o determinación de los sólidos solubles totales en manzana, kiwi, melón, banano, fresas, arándanos, peras y uvas (Leiva-Valenzuela y col., 2013; Peng y Lu, 2008; Rajkumar, Wang, Elmasry, Raghavan y Garipey, 2012).

Por otro lado, también se observa que se han utilizado una diversidad de técnicas de modelado, en mayor número a los reportados en el punto 2.1, estas pueden dividirse en técnicas para la reducción de la dimensionalidad (PCA, SPA, GDA, LDA, MNF, DW, MCUVE, HDR,

---

NG) y cuantificación (PLSR, PLSDA, PLSD, KNN, NN, BPNN, SVM, SVR, SVDD, TBRM, NB, DT, ELM) o clasificación (KNN, NN, BPNN, SVM, SVR, SVDD, TBRM, NB, DT, ELM, TRESHOLDING SEGMENTATION, ANOVA SEGMENTATION, PWCD); y se usan en una sucesión de tareas tal como se indicó en la Figura 1.4 y detalló en la Tabla 1.6.

### **1.5.2. En productos hortofrutícolas mínimamente procesados**

En los últimos años, se ha incrementado la demanda de vegetales, frutas y en general alimentos mínimamente procesados en fresco (MPF) y preparados para el consumo, destacando su frescura y comodidad de uso. Estos alimentos presentan un mayor riesgo de deterioro microbiano, debido principalmente a que no han sido sometidos a procesos rigurosos que disminuyan su carga microbiana; además, suelen estar confinados en envases pequeños (Sillani y Nassivera, In Press). La acidez, el uso de atmósferas modificadas, y otros factores favorecen el crecimiento microbiano como levaduras, convirtiéndose en agentes alterantes frecuentes y a veces dominantes en este tipo de alimentos, siendo productos altamente perecederos (Diezma, Lléo, Lunadei, Roger y Ruiz-Altisent, 2011; Ramos, Miller, Brandão, Teixeira y Silva, 2013). Este

hecho ha promovido numerosas investigaciones para el desarrollo de tratamientos que alarguen su vida útil; siendo las principales técnicas de preservación, aplicadas a estos productos, el almacenamiento en frío y el envasado en atmósferas modificadas, combinadas con tratamientos químicos (soluciones antimicrobianas, antioxidantes, etc.) y la aplicación de tratamientos de vapor o agua caliente (Artés, Gómez, Aguayo, Escalona y Artés-Hernández, 2009).

La generación de estos métodos requiere la evaluación de la seguridad y la calidad organoléptica de los productos obtenidos; la cual, hasta el momento, se ha llevado a cabo fundamentalmente mediante evaluaciones sensoriales y conteos microbiológicos, técnicas exigentes en tiempo y recursos. Consecuentemente, el sector precisa de técnicas baratas, rápidas, no invasivas y objetivas para evaluar la calidad general y seguridad de los productos MPF (Artés y Allende, 2014; Artés y col., 2009).

En respuesta a lo antes mencionado se ha venido explorando el uso de la técnica de imágenes hiperespectrales en la evaluación de productos agroalimentarios; determinando su potencial como herramienta de detección de contaminantes, identificación de defectos, estimación de la

---

composición analítica, determinación de atributos de calidad, entre otros (Diezma y col., 2011).

Estudios realizados en hojas de espinacas MPF, almacenados a 12 y 20 °C durante 9 días; evaluaron, en el rango espectral de 400 a 1000 nm, las principales diferencia determinando en región del verde (520-560 nm) decaimiento de los valores de intensidad a lo largo del almacenamiento; en tanto que a 756 nm fué posible observar regiones afectadas por podredumbres (Diezma y col., 2011). Por su lado; Aligbe, Diezma, y Díaz (2013), aplico esta tecnología a la determinación de contaminación microbiana en hojas de espinaca MPF, almacenadas a 8 °C durante 9 días, identificando contenidos microbianos superiores a 5 unidades logarítmicas.

### **1.6. Proyección futura y retos**

La técnica de imágenes hiperespectrales ha abierto diversas líneas de investigación, que aún son problemas que esta técnica tiene que superar, como:

- a) Estandarización de procesos de calibración, como paso previo al desarrollo de modelos generalizables.

- b) Control y evaluación físico-química y microbiológica de productos agropecuarios, agroindustriales y alimentos en general.
- c) Clasificación automática en la producción y comercialización de productos hortofrutícolas.
- d) Desarrollo de algoritmos y aplicaciones informáticas para el uso de la técnica de imágenes hiperespectrales y el análisis de imágenes.
- e) Aplicación de técnicas de inteligencia artificial para el manejo y análisis de imágenes hiperespectrales.
- f) Mejora de hardware y software para reducción de costo de equipo y aumento de la velocidad de medición.

Se espera que en el corto plazo estas barreras se puedan superar a fin de masificar a esta tecnología, posibilitando que la sociedad aproveche las ventajas previamente comentadas.

### **1.7. Conclusión**

La aplicación de la técnica de imágenes hiperespectrales es un campo complejo y multidisciplinario, que puede ser usado en forma eficiente y confiable en la medición de múltiples componentes químicos, así como

parámetros físicos, en forma simultánea, sin una preparación previa de la muestra; por tanto, ofrece la posibilidad de diseñar sistemas de control para la clasificación automática y la determinación de componentes de productos agroalimenticios. Diversos reportes de investigaciones descritos en esta revisión muestran la capacidad de utilizar las imágenes hiperespectrales para la clasificación de las muestras, detección de defectos, predicción de atributos químicos; así como, evaluaciones de la calidad global de frutas, verduras y otros productos agrícolas. En la actualidad existen algunos casos prácticos donde se vienen utilizando estos sistemas en tiempo real y se prevé la masificación del uso de estos sistemas en alimentos, aplicados en tiempo real, por ser una técnica que la industria agroalimentaria moderna requiere, para cumplir con los requisitos de calidad exigidos por el mercado.

### **Referencias bibliográficas**

- Abdel, E., Mutanga, O., Odindi, J., Adam, E., Odindo, A. y Ismail, R. (2014). A comparison of partial least squares (PLS) and sparse regressions (SR) for predicting yield of Swiss chard grown under different irrigation water sources using hyperspectral data. *Computers and Electronics in Agriculture*, 106, 11 – 19.

- 
- Aligbe, I., Diezma, B. y Díaz, V. (2013). Imagen Hiperespectral para la detección de contaminación microbiana en espinaca fresca envasada. VII Congreso Ibérico de Agroingeniería y ciencias hortícolas. Madrid-España.
  - Ariana, D. y Lu, R. (2010). Evaluation of internal defect and surface color of whole pickles using hyperspectral imaging. *Journal of Food Engineering*, 96(4), 583–590.
  - Ariana, D. y Lu, R. (2008). Quality evaluation of pickling cucumbers using hyperspectral reflectance and transmittance imaging: Part I. Development of a prototype. *Sensing and Instrumentation for Food Quality and Safety*, 2(3), 144–151.
  - Artés, F. y Allende, A. (2014). In Sun (Ed.), *Emerging Technologies for Food Processing*, 2nd Edition. Academic Press, San Diego.
  - Artés, F., Gómez, P., Aguayo, E., Escalona, V. y Artés-Hernández, F. (2009). Sustainable sanitation techniques for keeping quality and safety of fresh-cut plant commodities. *Postharvest Biology and Technology*, 51(3), 287–296.

- 
- Barbedo, J., Tibola, C. y Fernandes, J. (2015). Detecting Fusarium head blight in wheat kernels using hyperspectral imaging. *Biosystems Engineering*, 131, 65 – 76.
  - Chang, C. y Du, Q. (2004). Estimation of number of spectrally distinct signal sources in hyperspectral imagery. *Geoscience and Remote Sensing - IEEE Transactions On*, 42(3), 608–619.
  - Cheng, J., Sun, D., Pu, H., Chen, X., Liu, Y., Zhang, H. y Li, J. (2015). Integration of classifiers analysis and hyperspectral imaging for rapid discrimination of fresh from cold-stored and frozen-thawed fish fillets. *Journal of Food Engineering*, 161, 33 – 39.
  - Cho, B., Kim, M., Baek, I., Kim, D., Lee, W., Kim, J., ... Kim, Y. (2013). Detection of cuticle defects on cherry tomatoes using hyperspectral fluorescence imagery. *Postharvest Biology and Technology*, 76, 40 – 49.
  - Dai, Q., Cheng, J., Sun, D. y Zeng, X. (2014) Potential of hyperspectral imaging for non invasive determination of mechanical properties of prawn (*Metapenaeus ensis*). *Journal of Food Engineering*, 136, 64 – 72.

- 
- Deng, S., Xu, Y., Li, L., Li, X. y He, Y. (2013). A feature-selection algorithm based on Support Vector Machine-Multiclass for hyperspectral visible spectral analysis. *Journal of Food Engineering*, 119(1), 159 – 166.
  - Diezma, B., Lleó, L., Lunadei, L., Roger, J. y Ruiz, M. (2011). La imagen hiperespectral como herramienta de evaluación de la calidad de hortaliza de hoja mínimamente procesada. VI Congreso Ibérico de Agroingeniería, 5-7.
  - Du, C. y Sun, D. (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science & Technology*, 15(5), 230 –249.
  - Elmasry, G. y Sun, D. (2010). Principles of hyperspectral imaging technology. *Hyperspectral Imaging for Food Quality Analysis and Control*. Elsevier, Dublin.
  - ElMasry, G., Sun, D. y Allen, P. (2013). Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. *Journal of Food Engineering*, 117(2), 235 – 246.

- 
- ElMasry, G., Wang, N. y Vigneault, C. (2009). Detecting chilling injury in Red Delicious apple using hyperspectral imaging and neural networks. *Postharvest Biology and Technology*, 52(1), 1–8.
  - ElMasry, G., Wang, N., ElSayed, A. y Ngadi, M. (2007). Hyperspectral imaging for non destructive determination of some quality attributes for strawberry. *Journal of Food Engineering*, 81(1), 98–107.
  - Everard, C., Kim, M. y Lee, H. (2014). A comparison of hyperspectral reflectance and fluorescence imaging techniques for detection of contaminants on spinach leaves. *Journal of Food Engineering*, 143, 139 – 145.
  - Fernández, A., Lousada, J., Morais, J., Xavier, J., Pereira, J. y Melo-Pinto, P. (2013). Comparison between neural networks and partial least squares for intra-growth ring wood density measurement with hyperspectral imaging. *Computers and Electronics in Agriculture*, 94, 71 – 81.
  - Fernández, A., Franco, C., Mendes-Ferreira, A., Mendes-Faia, A., Costa, P. y 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.

- Fu, X., Kim, M., Chao, K., Qin, J., Lim, J., Lee, H., ... y Ying, Y. (2014). Detection of melamine in milk powders based on NIR hyperspectral imaging and spectral similarity analyses. *Journal of Food Engineering*, 124, 97–104.
- Gómez, J. (2010) Detección automática de podredumbres en cítricos mediante procesado avanzado de imágenes hiperespectrales. Universidad de Valencia, Valencia - España.
- Gómez, J., Blasco, J., Soria, E., Lorente, D., Escandell, P., Martínez, J., ... y Aleixos, N. (2013). Hyperspectral LCTF-based system for classification of decay in mandarins caused by *Penicillium digitatum* and *Penicillium italicum* using the most relevant bands and non-linear classifiers. *Postharvest Biology and Technology*, 82, 76 – 86.
- Gowen, A., O'Donnell, C., Cullen, P., Downey, G. y Frias, J. (2007) Hyperspectral imaging – an emerging process analytical tool for

- 
- food quality and safety control. *Trends in Food Science y Technology*, 18(12), 590–598.
- He, H., Wu, D. y Sun, D. (2014). Potential of hyperspectral imaging combined with chemometric analysis for assessing and visualizing tenderness distribution in raw farmed salmon fillets. *Journal of Food Engineering*, 126, 156 – 164.
  - Heaton, J. y Marangoni, A. (1996). Chlorophyll degradation in processed foods and senescent plant tissues. *Trends in Food Science y Technology*, 7(1), 8–15.
  - Huang, M., Wan, X., Zhang, M. y Zhu, Q. (2013). Detection of insect-damaged vegetable soybeans using hyperspectral transmittance image. *Journal of Food Engineering*, 116 (1), 45–49.
  - Kimiya, T., Sivertsen, A., Heia, K. (2013). VIS/NIR spectroscopy for non- destructive freshness assessment of Atlantic salmon (*Salmo salar* L.) fillets. *Journal of Food Engineering*, 116(3), 758 – 764.
  - Lara, M., Diezma, B., Lleó, L., Roger, J., Garrido, Y., Gil, M. y Ruiz, M. (2013). Aplicación de imagen hiperespectral para observar

---

el efecto de la salinidad en hojas de lechuga. VII Congreso Ibérico de Agroingeniería y Ciencias Hortícolas.

- Lee, W., Kim, M., Lee, H., Delwiche, S., Bae, H., Kim, D. y Cho, B. (2014). Hyperspectral near-infrared imaging for the detection of physical damages of pear. *Journal of Food Engineering*, 130, 1 – 7.
- Leiva, G., Lu, R. y Aguilera, J. (2013). Prediction of firmness and soluble solids content of blueberries using hyperspectral reflectance imaging. *Journal of Food Engineering*, 115(1), 91–98.
- Lilles, T., Kiefer, R. y Chipman, J. (2014). *Remote Sensing and Image Interpretation*. John Wiley y Sons. 5ta Ed. New York – USA.
- Liu, D., Sun, D. y Zen, X. (2013). Recent advances in wavelength selection techniques for hyperspectral image processing in the food industry. *Food and Bioprocess Technology*, 7, 307– 323.
- Lleó, L., Roger, J., Herrero, A., Barreiro, P., Diezma, B. y Ruiz, M. (2011). Comparación de índices ópticos de imágenes hiperespectrales en relación con madurez de melocotón: capacidad de detección y robustez. VI Congreso Ibérico de Agroingeniería.

- 
- Lorente, D., Zude, M., Regen, C., Palou, L., Gómez, J. y Blasco, J. (2013). Early decay detection in citrus fruit using laser-light backscattering imaging. *Postharvest Biology and Technology*, 86, 424 – 430.
  - Lu, R. y Ariana, D. (2013). Detection of fruit fly infestation in pickling cucumbers using a hyperspectral reflectance/transmittance imaging system. *Postharvest Biology and Technology*, 81, 44 – 50.
  - Lu, R. y Peng, Y. (2006). Hyperspectral scattering for assessing peach fruit firmness. *Biosystems Engineering*, 93(2), 161–171.
  - Ma, Y., Huang, M., Yang, B. y Zhu, Q. (2014). Automatic threshold method and optimal wavelength selection for insect-damaged vegetable soybean detection using hyperspectral images. *Computers and Electronics in Agriculture*, 106, 102 – 110.
  - Magwaza, L. y Opara, U. (2015). Analytical methods for determination of sugars and sweetness of horticultural products — A review. *Scientia Horticulturae*, 184, 179 – 192.
  - Mendoza, F., Lu, R. y Cen, H. (2014). Grading of apples based on firmness and soluble solids content using VIS/SWNIR spectroscopy

- 
- and spectral scattering techniques. *Journal of Food Engineering*, 125, 59 – 68.
- Mishra, P., Cordella, C., Rutledge, D., Barreiro, P., Roger, J. y Diezma, B. (2016). Application of independent components analysis with the \JADE\ algorithm and \NIR\ hyperspectral imaging for revealing food adulteration. *Journal of Food Engineering*, 168, 7 – 15.
  - Mizushima, A. y Lu, R. (2013). An image segmentation method for apple sorting and grading using support vector machine and Otsu's method. *Computers and Electronics in Agriculture*, 94, 29 – 37.
  - Naganathan, G., Cluff, K., Samal, A., Calkins, C., Jones, D., Lorenzen, C., Subbiah, J. (2015a). A prototype on-line \AOTF\ hyperspectral image acquisition system for tenderness assessment of beef carcasses. *Journal of Food Engineering*, 154, 1 – 9.
  - Naganathan, G., Cluff, K., Samal, A., Calkins, C., Jones, D., Lorenzen, C. y Subbiah, J. (2015b). Hyperspectral imaging of rib eye muscle on hanging beef carcasses for tenderness assessment. *Computers and Electronics in Agriculture*, 116, 55 – 64.

- 
- Peng, Y. y Lu, R. (2008). Analysis of spatially resolved hyperspectral scattering images for assessing apple fruit firmness and soluble solids content. *Postharvest Biology and Technology*, 48(1), 52–62.
  - Qin, J., Burks, T., Ritenour, M. y Bonn, W. (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering*, 93(2), 183–191.
  - Qin, J., Chao, K., Kim, M., Lu, R. y Burks, T. (2013). Hyperspectral and multispectral imaging for evaluating food safety and quality. *Journal of Food Engineering*, 118(2), 157 – 171.
  - Rady, A., Guyer, D., Kirk, W. y Donis-González, I. (2014). The potential use of visible/near infrared spectroscopy and hyperspectral imaging to predict processing- related constituents of potatoes. *Journal of Food Engineering*, 135, 11 – 25.
  - Rajkumar, P., Wang, N., Elmasry, G., Raghavan, G. y Garipey, Y. (2012). Studies on banana fruit quality and maturity stages using

- 
- hyperspectral imaging. *Journal of Food Engineering*, 108(1), 194–200.
- Ramos, B., Miller, F., Brandão, T., Teixeira, P. y Silva, C. (2013). Fresh fruits and vegetables — an overview on applied methodologies to improve its quality and safety. *Innovative Food Science y Emerging Technologies*, 20, 1–15.
  - Ravikanth, L., Singh, C., Jayas, D. y White, N. (2015). Classification of contaminants from wheat using near-infrared hyperspectral imaging. *Biosystems Engineering*, 135, 73 – 86.
  - Rivera, N., Gómez-Sanchis, J., Chanona-Pérez, J., Carrasco, J., Millán-Giraldo, M., Lorente, D., ... Blasco, J. (2014). Early detection of mechanical damage in mango using \NIR\ hyperspectral images and machine learning. *Biosystems Engineering*, 122, 91 – 98.
  - Rodríguez-Pulido, F., Barbin, D., Sun, D., Gordillo, B., González-Miret, M. y Heredia, F. (2013). Grape seed characterization by \NIR\ hyperspectral imaging. *Postharvest Biology and Technology*, 76, 74 – 82.

- 
- Rud, R., Shoshany, M. y Alchanatis, V. (2013). Spatial–spectral processing strategies for detection of salinity effects in cauliflower, aubergine and kohlrabi. *Biosystems Engineering*, 114(4), 384 – 396.
  - Sengupta, S. y Lee, W. (2014). Identification and determination of the number of immature green citrus fruit in a canopy under different ambient light conditions. *Biosystems Engineering*, 117, 51 – 61.
  - Serranti, S., Cesare, D. y Bonifazi, G. (2012). Hyperspectral-imaging-based techniques applied to wheat kernels characterization. In *SPIE Defense, Security, and Sensing*. International Society for Optics and Photonics.
  - Siedliska, A., Baranowski, P. y Mazurek, W. (2014). Classification models of bruise and cultivar detection on the basis of hyperspectral imaging data. *Computers and Electronics in Agriculture*, 106, 66 – 74.
  - Sillani, S. y Nassivera, F. (In Press). Consumer behaviour in choice of minimally processed vegetables and implications for marketing strategies. *Trends in Food Science y Technology*.

- 
- Simko, I., Jimenez-Berni, J. y Furbank, R. (2015). Detection of decay in fresh-cut lettuce using hyperspectral imaging and chlorophyll fluorescence imaging. *Postharvest Biology and Technology*, 106, 44 – 52.
  - Slaughter, D. (2009). Non destructive maturity assessment methods for mango: A Review of Literature and Identification of Future Research Needs. National Mango Board, Orlando, FL, USA.
  - Sun, D. (2010). *Hiperspectral Imaging for Food Quality Analisis And Control*. San Diego - USA.: Elsevier.
  - Tao, F., Peng, Y., Gomes, C., Chao, K. y Qin, J. (2015). A comparative study for improving prediction of total viable count in beef based on hyperspectral scattering characteristics. *Journal of Food Engineering*, 162, 38 – 47.
  - Tiwari, G., Slaughter, D. y Cantwell, M. (2013). Nondestructive maturity determination in green tomatoes using a handheld visible and near infrared instrument. *Postharvest Biology and Technology*, 86, 221 – 229.

- 
- Vélez-Rivera, N., Chanona-Pérez, J., Cubero, S., Aleixos, N., Calderón- Domínguez, G., Farrera, R. and Blasco, J. (2013). Evaluación de calidad y nivel de madurez en mangos cv. “Manila” mediante visión por computador. Presented at VI Congreso Ibérico de Agroingeniería y Ciencias Hortícolas, Madrid-España.
  - Wang, W., Ni, X., Lawrence, K., Yoon, S., Heitschmidt, G. y Feldner, P. (2015). Feasibility of detecting Aflatoxin \B1\ in single maize kernels using hyperspectral imaging. *Journal of Food Engineering*, 166, 182 – 192.
  - Wouters, N., Ketelaere, B., Deckers, T., Baerdemaeker, J. y Saeys, W. (2015). Multispectral detection of floral buds for automated thinning of pear. *Computers and Electronics in Agriculture*, 113, 93 – 103.
  - Wu, D. y Sun, D. (2013a). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review — Part I: Fundamentals.
  - Wu, D. y Sun, D. (2013b). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and

- 
- assessment: A review — Part II: Applications. *Innovative*, 19, 15–28.
- Xing, J. y De Baerdemaeker, J. (2005). Bruise detection on “Jonagold” apples using hyperspectral imaging. *Postharvest Biology and Technology*, 37(2), 152–162.
  - Xiong, Z., Sun, D., Zeng, X. y Xie, A. (2014). Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: A review. *Journal of Food Engineering*, 132, 1–13.
  - Yang, C., Kim, M., Millner, P., Chao, K., Cho, B., Mo, C., ... Chan, D. (2014). Development of multispectral imaging algorithm for detection of grass on mature red tomatoes. *Postharvest Biology and Technology*, 93, 1 – 8.
  - Yang, C., Lee, W. y Gader, P. (2014). Hyperspectral band selection for detecting different blueberry fruit maturity stages. *Computers and Electronics in Agriculture*, 109, 23 – 31.
  - Yang, Y., Sun, D., Pu, H., Wang, N. y Zhu, Z. (2015). Rapid detection of anthocyanin content in lychee pericarp during storage

---

using hyperspectral imaging coupled with model fusion. *Postharvest Biology and Technology*, 103, 55 – 65.

- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J. y 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.
- Zhang, B., Li, J., Fan, S., Huang, W., Zhao, C., Liu, C. y Huang, D. (2015). Hyperspectral imaging combined with multivariate analysis and band math for detection of common defects on peaches (*Prunus persica*). *Computers and Electronics in Agriculture*, 114, 14 – 24.
- Zhang, X., Liu, F., He, Y. y Gong, X. (2013). Detecting macronutrients content and distribution in oilseed rape leaves based on hyperspectral imaging. *Biosystems Engineering*, 115(1), 56 – 65.
- Zhou, R., Kaneko, S., Tanaka, F., Kayamori, M. y Shimizu, M. (2015). Image- based field monitoring of *Cercospora* leaf spot in sugar beet by robust template matching and pattern recognition. *Computers and Electronics in Agriculture*, 116, 65 – 79.

=====

## **2. Materiales y métodos**

=====

## **2.1. Introducción**

La labor de investigación de la presente tesis se centró en la aplicación de la técnica de imágenes hiperespectrales a tres casos de estudio del sector agropecuario de la región Amazonas en Perú. En tal sentido; siendo dicha técnica el punto focal de esta investigación, una buena parte de los materiales y métodos son de uso general para los tres casos. Por tanto; en las próximas páginas se abordarán los materiales y métodos comunes a todas las labores experimentales realizadas para esta tesis, dejando las particularidades para los capítulos donde se presenta cada caso de estudio.

## **2.2. Montaje y puesta a punto del sistema de adquisición de imágenes hiperespectrales**

El sistema de adquisición y análisis de imágenes hiperespectrales, como se ha explicado en el Capítulo I, es un elemento esencial en el desarrollo de las labores de investigación; debiendo asegurar la obtención de imágenes de calidad, reduciendo así el tiempo y necesidad de pre-procesamiento a aplicar sobre las imágenes obtenidas (Elmasry y Sun, 2010; Wu y Sun, 2013). En la presente investigación se construyó un

sistema de adquisición de imágenes cuyos elementos (hardware y software) se explicarán en detalle en las siguientes líneas.

### 2.2.1. Hardware

El hardware, constituido por la parte física del sistema, comprende los elementos mostrados en la Figura 2.1.

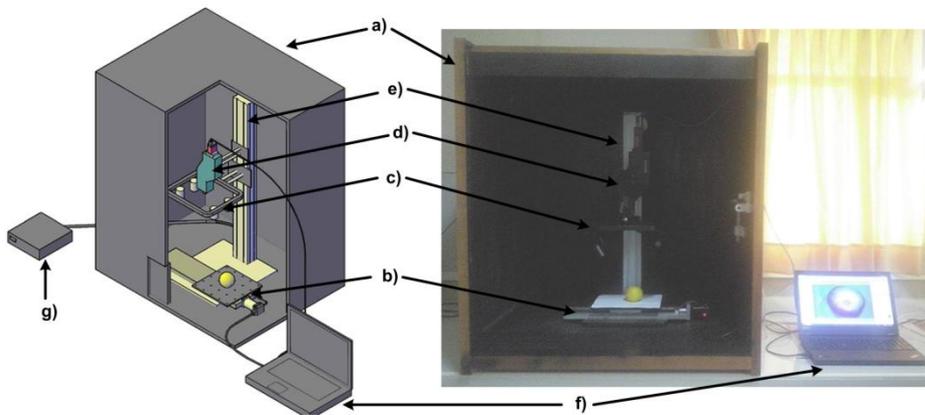


Figura 2. 1 Elementos físicos del sistema de adquisición de imágenes hiperespectrales a) cubierta exterior b) plataforma de muestra c) sistema de iluminación d) cámara y espectrógrafo e) torre f) computador g) fuente de alimentación

Algunos detalles del mismo se brindan a continuación:

a) Cubierta exterior.

- Función: evitar la influencia de la iluminación exterior sobre la muestra.
- Especificaciones:

- Material: madera

- 
- Dimensiones: 0.60 x 0.6 x 0.9 m
  - Color interior: negro mate
  - Puerta de ingreso de muestras: 0.20 x 0.20 m

b) Plataforma de muestra

- Función: trasladar muestras pequeñas a través del campo de visión de la cámara
- Especificaciones
  - Plataforma: metálica
  - Dimensiones (cm): 20 x 20
  - Velocidad (cm/s): 0.079 – 15.870
  - Distancia máxima (cm) 30
  - Requerimiento de poder (V /A): 12/2

c) Sistema de iluminación

- Función: Iluminación de la muestra
- Especificaciones:
  - Numero de unidades: 4
  - Requerimiento de poder (V /A): 220/4

d) Cámara y espectrografo

- Función: Adquisición de imágenes de intensidad a diferentes longitudes de onda.

- 
- Especificaciones:
    - Rango espectral (nm): 400 – 1000
    - Resolución espectral (nm): 2.5
    - Canales espectrales: 240
    - Canales espaciales: 1600
    - Máxima tasa de fotogramas (fps): 242
    - Profundidad de bits: 14
    - Dimensiones (cm): 12.4 x 23.9 x 8.4
    - Conexión: GigE
    - Rango de temperatura (°C): 0 - 45
    - f/#: 2.4
    - Lente: Schneider Xenoplan
    - Longitud focal: 23 mm
  - Fabricante: RESONON - USA
- e) Torre
- Función: Soporte ajustable de sistema de iluminación, cámara y espectrografo.
  - Especificaciones:
    - Material: Aluminio
    - Superficie: Acanalada

- 
- Altura (cm): 81
  - Fabricante: RESONON - USA
- f) Computador:
- Función: Gestión del software de adquisición de imágenes.
  - Especificaciones:
    - Procesador: Intel I-7
    - Memoria: 4 GB
    - Disco duro: 120 GB
    - Memoria de video dedicada: Nvidia Gforce 12400
  - Fabricante: LENOVO - USA

### **2.3. Software de adquisición de datos**

Para la adquisición de imágenes y administración de recursos físicos del sistema, se usó el software Spectronon 2.62, RESONON Inc. – USA. Este software permite al usuario accionar la cámara, el difusor y la plataforma de muestra; fijando parámetros como tasa de adquisición de fotogramas, longitudes de onda a muestrear, velocidad de desplazamiento de plataforma, entre otras y cuenta con una interfaz, Figura 2.2 que permite visualizar la imagen adquirida en formato RGB e

imágenes de intensidad a diferentes longitudes de onda, además de selección y análisis de espectros puntuales y de área.

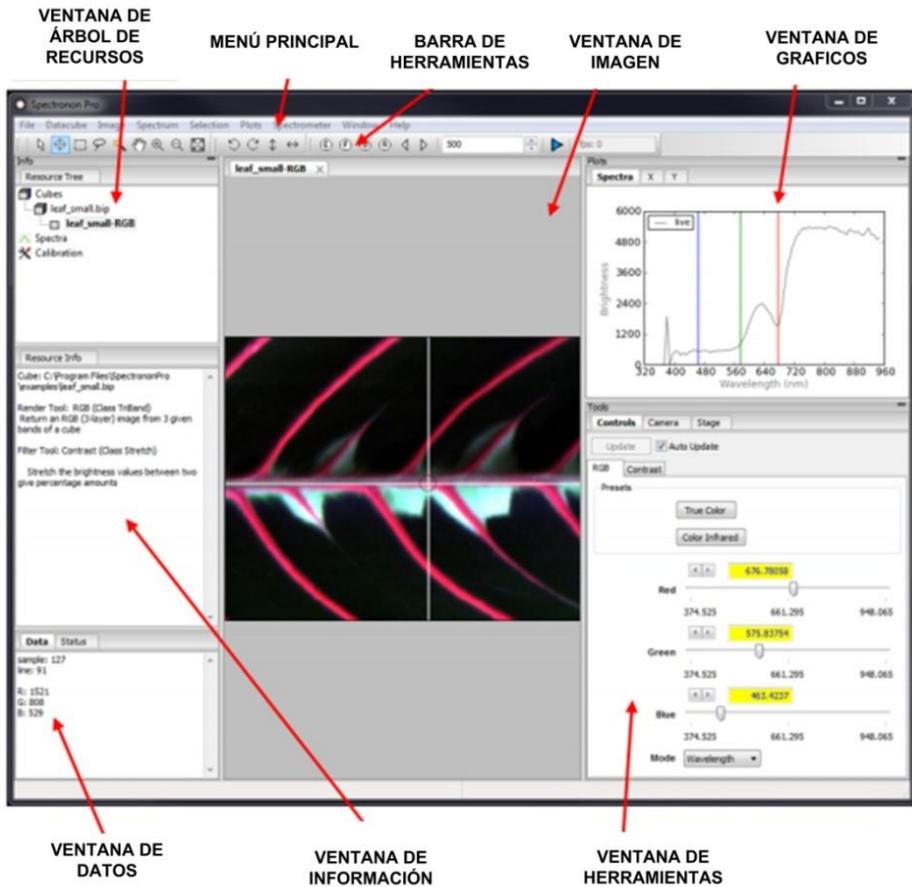


Figura 2. 2 Interfaz de usuario del software Spectronon 2.62  
Fuente: Resonon (2015)

Aunque este software cuenta con algunas funciones desarrolladas para el análisis rápido de imágenes hiperespectrales, como cálculo de índices de reflectancia de carotenoides, antocianinas, mejoramiento vegetativo, fotoquímico, entre otros, véase Tabla 2. 1.

Tabla 2. 1 Índices espectrales analizados por el software Spectronon 2.62

Índice hyperspectral	Ecuación en Spectronon
Reflectancia de antocianinas, índice 1	$ARI1 = \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}}$
Reflectancia de antocianinas, índice 2	$ARI2 = \rho_{900} \left( \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \right)$
Vegetación atmosféricamente resistente	$ARVI = \frac{NIR - (Red - \gamma(Blue - Red))}{NIR + (Red - \gamma(Blue - Red))}$
Reflectancia de carotinoides, índice 1	$CRI1 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}}$
Reflectancia de carotinoides, índice 2	$CRI2 = \frac{1}{\rho_{510}} - \frac{1}{\rho_{700}}$
Vegetativo mejorado	$EVI = \frac{NIR - Red}{NIR + 6.0(Red) - 7.5(Blue) + 1}$
Modificado de reflectancia de absorción de clorofila	$MCARI = \rho_{700} - \rho_{670} - 0.2(\rho_{700} - \rho_{550}) \left( \frac{\rho_{700}}{\rho_{670}} \right)$
Vegetación normalizada en limite rojo	$MRENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2(\rho_{445})}$
Ratio simple modificada de limite rojo	$MRESR = \frac{\rho_{750} - \rho_{705}}{\rho_{705} + \rho_{445}}$
Diferencia vegetativa normalizada	$NDVI = \frac{NIR - Red}{NIR + Red}$
Reflectancia fotoquímica	$PRI = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}}$
Reflectancia de senescencia vegetal	$PSRI = \frac{\rho_{600} - \rho_{500}}{\rho_{750}}$
Tasa simple	$SR = \frac{NIR}{Red}$
Estructura de pigmento no sensitivo	$SIPi = \frac{\rho_{900} - \rho_{445}}{\rho_{900} + \rho_{680}}$
Limite rojo Vogelmann, índice 1	$VREI1 = \frac{\rho_{740}}{\rho_{720}}$
Limite rojo Vogelmann, índice 2	$VREI2 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} - \rho_{726}}$
Limite rojo Vogelmann, índice 3	$VREI3 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{720}}$
Banda de agua	$WBI = \frac{\rho_{970}}{\rho_{900}}$

Fuente: Resonon (2015)

De la tabla anterior se desprende que el software Spectronon 2.62 no cuenta con análisis de infección por roya, cuantificación de almidón o

---

presencia de grasa, labores de esta investigación y en tal sentido fue necesario desarrollar un software que cubra estos análisis; el desarrollo del software para el procesamiento y análisis de las imágenes hiperespectrales es detallado en el Capítulo III.

#### **2.4. Puesta en marcha del sistema de adquisición de imágenes**

El sistema de adquisición de imágenes debe ser puesto en marcha previo a la adquisición de las imágenes; procediéndose de acuerdo a los siguientes pasos:

- a) Conectar a toma de energía computador, fuente de energía para sistema de iluminación, cámara y espectrógrafo.
- b) Encender sistema de iluminación y esperar 30 minutos a estabilización de la emisión de las luces.
- c) Encender computador e iniciar software Spectronon 2.62.
- d) Verificar que los controladores (drivers) de la cámara, espectrógrafo y plataforma de muestra se hayan activado; caso contrario reiniciar el computador.
- e) Establecer los parámetros de funcionamiento de la cámara, espectrógrafo y plataforma de muestra a los valores indicados en la

Tabla 2.2 estos valores se establecieron, tomando en cuenta el manual de usuario del fabricante, durante la calibración del sistema.

Tabla 2. 2 Parámetros de adquisición de imagen hiperespectrales con el software Spectronon 2.62

<b>Elemento</b>	<b>Parámetro</b>	<b>Valor</b>
Cámara	Fotogramas por segundo (Hz)	31
	Tiempo de integración (ms)	15
	Ganancia (dB)	0
Espectrógrafo	Espectro por pixel	1
	Rango espectral (nm)	0-1200
	Precisión (nm)	8
	Solape (nm)	1
Plataforma de muestra	Velocidad de escaneo (cm/s)	0.5
	Velocidad de retorno	8.0

## 2.5. Cargado de imágenes para corrección espacial

La corrección espacial, proceso común para el pre-procesamiento de imágenes hiperespectrales en investigaciones como Elmasry y Sun (2010); Fukuda y col. (2014); Lee y col. (2014); Opara y Pathare (2014); Ravikanth y col. (2015) se realizó mediante una función automática en el software de adquisición de imágenes, de acuerdo a lo mostrado en la figura 1.4 del Capítulo I, con la finalidad de reducir el efecto de la distribución no homogénea de la luz en el campo de visión de la cámara.

Esta corrección uso imágenes de referencia negro ( $R_D$ ) y blanco ( $R_W$ ). La  $R_D$  se adquiere de un patrón de teflón, con valor de reflectancia ~99.9 %

y la  $R_W$  se adquiere al cubrir la lente con una tapa oscura, reflectancia  $\sim 0.0\%$ , véase Figura 2.3.

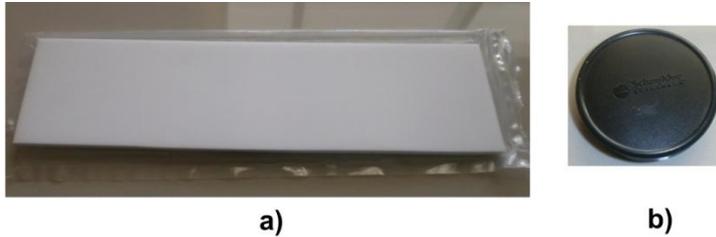


Figura 2.3 a) Patrón de teflón para  $R_W$  b) Cubierta del lente para  $R_D$

La corrección de las imágenes se realizó mediante la ecuación 1.1.

$$R_c = (R - R_D) / (R_W - R_D) \dots \text{Ec. 1.1}$$

Donde:

- $R_c$  = imagen hiperespectral corregida en reflectancia relativa
- $R$  = imagen hiperespectral en bruto
- $R_D$  = imagen en negro
- $R_w$  = imagen de referencia en blanco.

## 2.6. Adquisición de imágenes

Las muestras en estudio se dispusieron en la plataforma de desplazamiento del sistema de adquisición de imagen hiperespectrales, Figura 2. 4.

Mé debate el software se procedió al escaneo de las muestras; visualizando una imagen en seudo RGB. Esta imagen se procedió a almacenar en el disco duro del ordenador en formato \*.bil<sup>1</sup>.

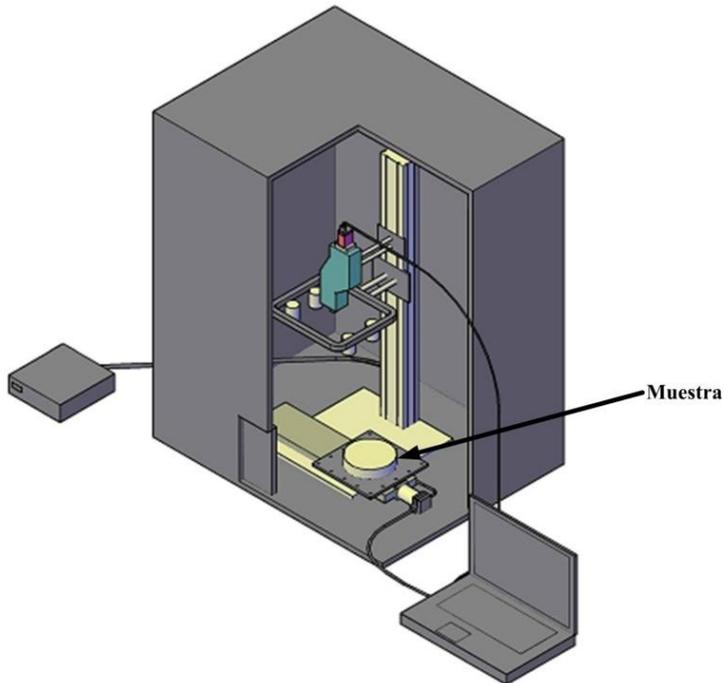


Figura 2. 4 Posicionamiento de hojas de café en sistema de adquisición de imágenes hiperespectrales

## 2.7. Segmentación por umbralizado

La segmentación es una técnica rápida para caracterizar las regiones de una imagen basada en las constantes de reflectancia o absorbancia de sus superficies; agrupando aquellos pixeles similares a fin de formar regiones

<sup>1</sup> El formato \*.bil se ha comentado en el apartado 1.1.3 del Capítulo I.

representativas (Brosnan y Sun, 2004) y ha sido usada como parte del análisis de imágenes hiperespectrales en trabajos como los de Lee y col., (2014); Yang y col., (2014) los cuales han clasificado exitosamente regiones con daño en peras y tomates respectivamente. Por ejemplo en el estudio de la roya (Capítulo IV) se usó esta técnica para el reconocimiento de pixeles de la hoja y el fondo, Figura 2.5 .

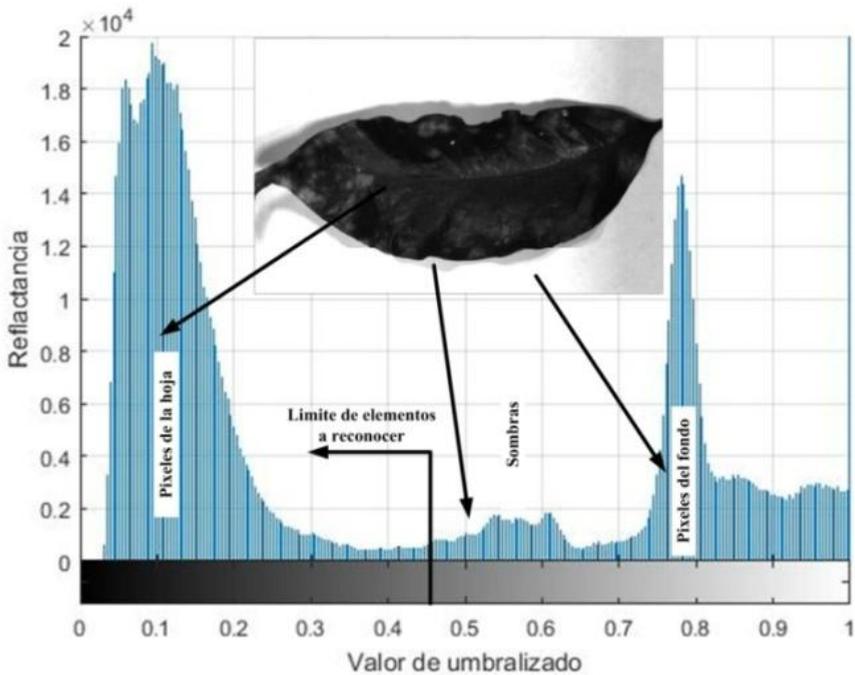


Figura 2.5 Histograma de imagen de intensidad de una hoja de café con daño por roya. La segmentación se realizó sobre las imágenes de intensidad a 562 nm, usando el valor de umbralizado de 0.45 y tal como se observa en la Figura 2.6 permitió diferenciar entre píxeles correspondientes al fondo y a la hoja; constituyendo estos últimos nuestras regiones de interés.

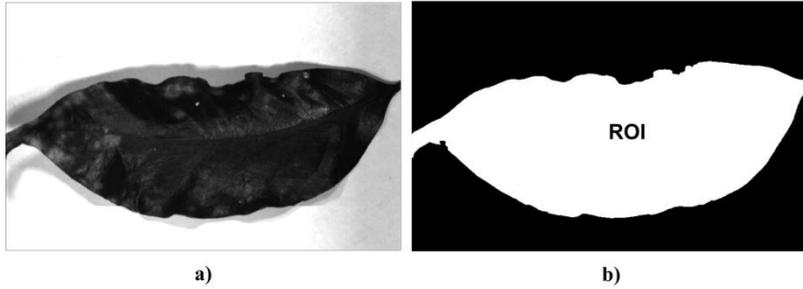


Figura 2. 6 a) imagen de intensidad a 562 nm b) imagen segmentada

El método de segmentación por umbralizado es utilizado en las restantes muestras (queso fresco y carne de res) fijándose en cada caso sus particulares condiciones detalladas en los capítulos correspondientes a cada estudio.

## 2.8. Conclusiones

El sistema de adquisición de imágenes hiperespectrales por reflectancia se implementó y puso en marcha de forma satisfactoria, permitiendo obtener imágenes hiperespectrales de las diferentes muestras a ser usadas en las labores experimentales.

La adquisición de imágenes hace uso del software Spectronon 2.62; dicho software, cuenta con algunas funciones para el análisis de imágenes, no permite evaluar en forma directa los parámetros de calidad para los casos concretos de hojas de café, muestras de queso y carne de

---

res. En este sentido es necesario elaborar un software que contemple las necesidades de pre-procesamiento y análisis de estos casos en particular.

### **Referencias bibliográficas**

- Brosnan, T., y Sun, D. (2004). Improving quality inspection of food products by computer vision—a review. *Journal of Food Engineering*, 61(1), 3–16.
- Elmasry, G., y Sun, D. (2010). Hyperspectral imaging for food quality analysis and control. In *Principles of hyperspectral imaging technology*. Dublin: Elsevier.
- Fukuda, S., Yasunaga, E., Nagle, M., Yuge, K., Sardud, V., Spreer, W., y Müller, J. (2014). Modelling the relationship between peel colour and the quality of fresh mango fruit using Random Forests. *Journal of Food Engineering*, 131, 7 – 17.
- Lee, W., Kim, M., Lee, H., Delwiche, S., Bae, H., Kim, D., y Cho, B. (2014). Hyperspectral near-infrared imaging for the detection of physical damages of pear. *Journal of Food Engineering*, 130, 1 – 7.
- Opara, U., y Pathare, P. (2014). Bruise damage measurement and analysis of fresh horticultural produce —A review. *Postharvest Biology and Technology*, 91, 9 – 24.

- 
- Ravikanth, L., Singh, C., Jayas, D., y White, N. (2015). Classification of contaminants from wheat using near-infrared hyperspectral imaging. *Biosystems Engineering*, 135, 73–86.
  - Resonon. (2015). *Benchtop System Users Manual*.
  - Wu, D., y Sun, D. (2013). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review — Part I: Fundamentals.
  - Yang, C., Kim, M., Millner, P., Chao, K., Cho, B., Mo, C., ... Chan, D. (2014). Development of multispectral imaging algorithm for detection of frass on mature red tomatoes. *Postharvest Biology and Technology*, 93, 1 – 8.

---

---

**3. Desarrollo de aplicación informática para pre-procesamiento y análisis de imágenes hiperespectrales**

---

---

---

### 3.1. Introducción

El análisis de imágenes hiperespectrales requiere del uso de herramientas informáticas especializadas, que cuenten con la opción de aplicar a la totalidad del hipercubo<sup>2</sup>, o ROIs, correcciones (espectral, espacial, curvatura), selección de ROIs, reducción de dimensionalidad y modelado de relaciones.

En este sentido la revisión realizada en el Capítulo I comenta, en la Tabla 1.2, los principales programas informáticos utilizados y su aplicación en recientes investigaciones con la tecnología de imágenes hiperespectrales. Entre ellos se encuentra Matlab (The Math-Works Inc.), ENVI (Research Systems Inc.), Unscrambler (CAMO Software), JMP (SAS Institute Inc.), R (Development Core Team) entre otros (Abdel y col., 2014; Barbedo, Tibola y Fernandes, 2015; Fernandes y col., 2013; Everard, Kim y Lee, 2014; Mishra y col., 2016; Rud, Shoshany y Alchanatis, 2013; Simko, Jimenez-Berni y Furbank, 2015). Estos programas cuentan con rutinas preestablecidas para el pre-procesamiento y análisis de imágenes hiperespectrales o en su defecto debieron implementarse por los investigadores para las condiciones del muestreo y/o su posible uso como

---

<sup>2</sup>Las definiciones de hipercubos y ROIs se encuentran en el Capítulo II

---

herramienta industrial como en el caso de la investigación de Gómez-Sanchis y col. (2008) quienes desarrollaron aplicaciones para la determinación de la calidad en cítricos, o más recientemente Naganathan y col. (2015a, 2015b) quienes desarrollaron un sistema para el análisis de la ternura de carne de res evaluando el músculo *longinuss dorsi* en el ojo de la costilla; estos sistemas han sido implementados en el software matemático Matlab, implementando para sus especiales necesidades funciones en lenguaje Script. Sin embargo; estas aplicaciones son esencialmente herramientas de laboratorio y no se han desarrollado con miras al uso industrial o comercial, reduciendo por ende su impacto.

En esta tesis se desarrolló una herramienta informática capaz de facilitar, entre otras, las siguientes operaciones:

- Pre-procesamiento de imágenes.
- Análisis de infección por roya en hojas de café.
- Determinación de adulteración de queso con harina de maíz.
- Evaluación del marmoleado en carne de res

El objetivo general de este Capítulo fue el desarrollo de una herramienta informática para el análisis de tres problemas en productos agropecuarios de la región Amazonas – Perú, mediante la tecnología de imágenes

---

hiperespectrales. Este objetivo general se dividió en los objetivos parciales siguientes:

- Desarrollo de requerimientos operacionales.
- Desarrollo de especificaciones técnicas.
- Desarrollo de la arquitectura del sistema.
- Desarrollo de aplicación en Matlab 2010<sup>a</sup> .

### **3.2. Materiales y métodos**

#### **3.2.1. Materiales**

Para el desarrollo del trabajo se utilizaron el material bibliográfico, paquetes informáticos y hardware que a continuación se detallan:

- *Material bibliográfico.* Para el desarrollo del software se consultaron diferentes referencias científicas sobre la aplicación de la tecnología de imágenes hiperespectrales; priorizando aquellas que daban información sobre las funciones aplicadas en cada paso del pre-procesamiento y análisis. Resultaron de especial importancia las siguientes referencias: Amigo, Martí y Gowen (2013); Brosnan y sun (2002); Elmasry, Barbin, Sun y Allen (2012); Gómez-Sanchis y col. (2008); Sun(2010)

- 
- *Paquetes informáticos.* Los paquetes informáticos utilizados para el desarrollo de la aplicación son propiedad de Microsoft Corporation (Redmond, Washington) y The Math-Works Inc. (Natick- USA) y se utilizaron bajo la licencia académica de e-academy Inc. Dichos paquetes se listan a continuación:

- Microsoft Visio 2007
- Microsoft Excel 2007
- Microsoft Access 2007
- Matlab 2010a

- *Hardware.* El hardware con el cual se desarrolló la aplicación tiene las siguientes características:

Procesador: Intel (R) Core (TM) i7 4700 MQ CPU@ 2.4 GHz

Memoria: 8.00 GB

Tipo de sistema: 64 bits

Disco duro: 120 GB

### **3.2.2. Metodología**

La metodología empleada fue la utilizada normalmente en proyectos de desarrollo de software (Fairley, 2011; Jacobson, Booch, Rumbaugh, Rumbaugh y Booch, 1999; McConnell, 2004). Consiste básicamente en la división de la labor en diferentes etapas, las cuales se describen esquemáticamente en la Figura 3. 1.

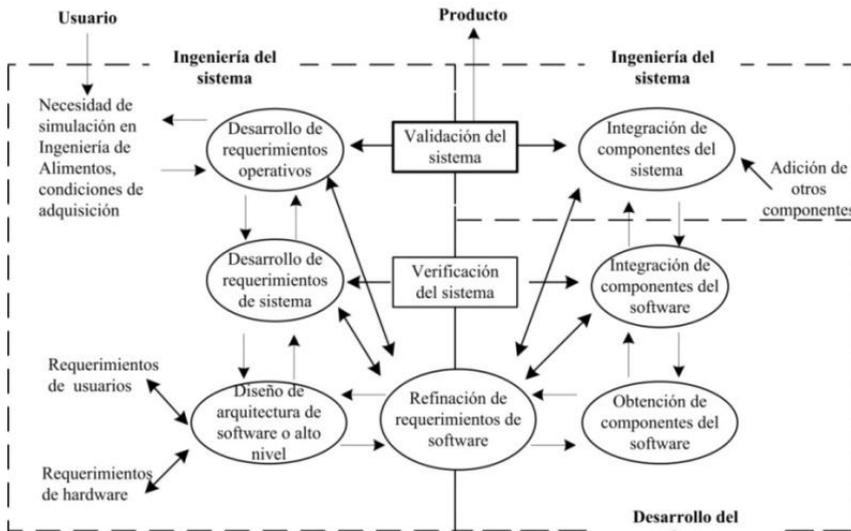


Figura 3. 1 Etapas del trabajo  
Fuente: Adaptado de Fairley (2011)

De una forma más detallada, las principales etapas son las siguientes:

### 3.2.2.1. Desarrollo de requerimientos

En esta fase se definieron los requerimientos operacionales y del sistema. Los requerimientos operacionales son los requerimientos que los usuarios e interesados en el sistema informático registraron en un listado, el cual es la base para posteriores validaciones y verificaciones (Fairley, 2011).

Los requerimientos operacionales fueron definidos mediante reuniones con tesisas e investigadores que viene realizando labores con la tecnología de imágenes hiperespectrales. Asimismo, se definieron los requisitos del sistema informático, derivados de los requerimientos

operacionales, en los cuales se especifica la calidad y atributos técnicos que el sistema debe proveer para satisfacer los requerimientos operacionales (Munson, 2005).

### 3.2.2.2. Desarrollo de la arquitectura del sistema

En la siguiente fase se procedió al desarrollo de la arquitectura del sistema informático. Dicha arquitectura, tal y como propone McConnell (2004), presenta varios niveles de abstracción y se esquematiza en la Figura 3. 2.

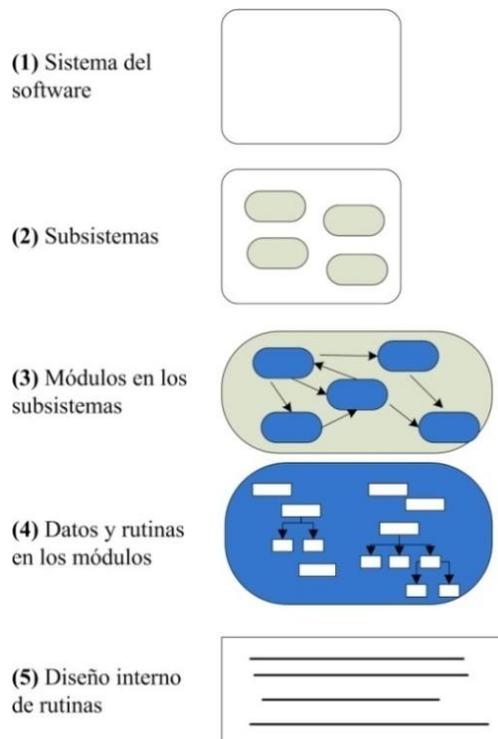


Figura 3. 2 Niveles en el diseño de un software  
Fuente: Adaptado de McConnell, 2004)

---

A continuación se brindan mayores detalles de los niveles anteriormente comentados:

- *Nivel 1: Sistema del software.* Este nivel, también conocido como “diseño de alto nivel” o “diseño de nivel superior”, presenta a grandes rasgos el diseño del sistema informático. El sistema informático se representa utilizando un diagrama de bloques, para ilustrar el hardware primario, software y usuarios o elementos, más las conexiones entre estos (Fairley, 2011). La información base para desarrollar este nivel se obtuvo a partir de los requisitos operacionales y del sistema.
- *Nivel 2: Subsistemas.* En este nivel se identifican los principales subsistemas. Estos subsistemas suelen ser grandes bases de datos, interfaces de usuarios, etc. En este nivel es de especial importancia especificar las reglas de comunicación entre subsistemas.
- *Nivel 3: Módulos.* El diseño a este nivel incluye la identificación de todos los módulos de un sistema informático y la forma en que estos se ordenan en un flujo de información; además, se detalla la interacción de estos con el resto del sistema informático y deben definirse claramente las interfaces. El desarrollo a este nivel se realizó como lo proponen Dobre y Marcano (2007) usando una

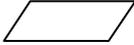
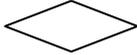
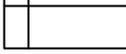
---

aproximación modular secuencial y la propuesta para la aplicación de la tecnología de imágenes hiperespectrales de la Figura 1.4 del Capítulo I.

- *Nivel 4: Rutinas.* En este nivel se procede a dividir cada módulo en rutinas, detallando las rutinas específicas de cada módulo. Las rutinas principales para el pre-procesamiento (corrección espectral, eliminación de anómalos, selección de ROIs manual, segmentación, extracción de información espectral) y análisis de imágenes hiperespectrales (entrenamiento de clasificadores, modelado, aplicación de clasificadores y modelos). Estas rutinas fueron desarrolladas en un proceso iterativo y aplicadas en las labores experimentales de la presente tesis.

Las secuencias lógicas usadas para esquematizar estas rutinas se construyen con los símbolos mostrados en la Tabla 3.1.

Tabla 3. 1 Simbología para la construcción secuencias lógicas

Símbolo	Descripción
	Uso de constantes o variables durante ejecución del software
	Ingreso de información por periféricos (teclado o mouse)
	Búsqueda, envío de información, creación de objetos, etc
	Sentencia de decisión, comparación
	Almacenamiento de información en memoria operativa
	Presentación de información en pantalla
	Fin de acción en una rutina
	Almacenamiento en disco
	Flujo de acción y envío de información entre operaciones de una rutina
	Flujo de información secundaria o alterna

### 3.2.2.3. Validación de secuencias lógicas

Al concluir el desarrollo de las secuencias lógicas se procedió a la validación de las mismas; lo cual se realizó determinando si estas son adecuadas para los fines previstos en el ambiente de trabajo (Munson, 2005).

### 3.2.2.4. Implementación del software

Paralelamente al proceso de validación se procedió a implementar las secuencias lógicas en Matlab 2010a; la codificación siguió las

---

recomendaciones del apartado sobre la arquitectura del sistema, apartado 3.2.2.2, y el desarrollo el software en una estructura modular.

### **3.3. Resultados y discusión**

#### **3.3.1. Requerimientos operacionales**

Se elaboraron los requerimientos operacionales del sistema informático y principalmente del software de aplicación de la tecnología de imágenes hiperespectrales (Hyper\_1), al cual nos referiremos a partir de este apartado como *software*.

#### **3.3.2. Características operacionales**

- El software cargara imágenes hiperespectrales, hipercubos, en formatos \*.bil y \*.bsq; por ser estos los formatos generados por el sistema de adquisición con que se cuenta en este proyecto. Para la lectura de este hipercubo se hace uso de los parámetros contenidos en el archivo de cabecera \*.hdr, véase ejemplo en Figura 3. 3, de tal manera que la herramienta informática, para cargar cada hipercubo, requiere contar con dos archivos pares uno de datos \*.bil ò \*. bsq y la cabecera de extensión \*.hdr.

```

ENVI
envi
interleave = bil
data type = 12
lines = 182
samples = 177
bands = 150
bit depth = 14
shutter = 15.0
gain = 0
framerate = 61.2407373385
reflectance scale factor = 16383
byte order = 0
header offset = 0
wavelength= (0.0, 8.0, 16.0, 24.0, 32.0, 40.0, 48.0, 56.0, 64.0, 72.0, 80.0, 88.0,
96.0, 104.0, 112.0, 120.0, 128.0, 136.0, 144.0, 152.0, 160.0, 168.0, 176.0,
184.0, 192.0, 200.0, 208.0, 216.0, 224.0, 232.0, 240.0, 248.0, 256.0, 264.0,
272.0, 280.0, 288.0, 296.0, 304.0, 312.0, 320.0, 328.0, 336.0, 344.0, 352.0,
360.0, 368.0, 376.0, 384.0, 392.0, 400.0, 408.0, 416.0, 424.0, 432.0, 440.0,
448.0, 456.0, 464.0, 472.0, 480.0, 488.0, 496.0, 504.0, 512.0, 520.0, 528.0,
536.0, 544.0, 552.0, 560.0, 568.0, 576.0, 584.0, 592.0, 600.0, 608.0, 616.0,
624.0, 632.0, 640.0, 648.0, 656.0, 664.0, 672.0, 680.0, 688.0, 696.0, 704.0,
712.0, 720.0, 728.0, 736.0, 744.0, 752.0, 760.0, 768.0, 776.0, 784.0, 792.0,
800.0, 808.0, 816.0, 824.0, 832.0, 840.0, 848.0, 856.0, 864.0, 872.0, 880.0,
888.0, 896.0, 904.0, 912.0, 920.0, 928.0, 936.0, 944.0, 952.0, 960.0, 968.0,
976.0, 984.0, 992.0, 1000.0, 1008.0, 1016.0, 1024.0, 1032.0, 1040.0, 1048.0,
1056.0, 1064.0, 1072.0, 1080.0, 1088.0, 1096.0, 1104.0, 1112.0, 1120.0,
1128.0, 1136.0, 1144.0, 1152.0, 1160.0, 1168.0, 1176.0, 1184.0, 1192.0)
rotation = [(0, 0), (0, 1), (1, 0), (1, 1)]
label = M3.2a

```

Figura 3. 3 Archivo en formato \*.hdr para una muestra de queso

- El software, mediante distintos módulos, permite al usuario:
  - *Cargado y visualización de hipercubos.* Este módulo permite: i) cargar los hipercubos en memoria; ii) visualizar una imagen en pseudo RGB e imágenes de intensidad a diferentes longitudes de onda.
  - *Detección de infección temprana por roya en hojas de café.* Este modulo permite: i) extraer información de diferentes ROIs (seleccionadas manualmente) en hojas de café; ii) generar un clasificador entrenado (basado en el método de árbol de decisiones) y clasificar nuevas hojas mediante este clasificador; iii) el módulo

- 
- genera como resultados una imagen coloreada para los diferentes niveles de daño y una gráfica porcentual del mismo.
- *Determinación de adulteración por harina de maíz.* Este módulo permite: i) reconocer automáticamente regiones de interés en muestras de queso de forma cilíndrica; ii) extraer los perfiles espectrales de cada pixel contenido en las ROIs; iii) eliminar perfiles espectrales anómalos y generar un perfil espectral promedio; iv) modelar la relación entre los perfiles espectrales y el contenido de almidón en muestras de queso fresco, mediante regresión de mínimos cuadrados parciales (PLSR) y v) aplicar el modelo PLSR para determinar el contenido de almidón en muestras de queso fresco.
  - *Determinación de marmoleo en carne de res.* Este módulo permite: i) obtener ROIs mediante segmentación por umbralizado de muestras de *longinissus dorsi*; ii) extraer información espectral; iii) eliminar pixeles anómalos; iv) desarrollar un clasificador entrenado (basado en el método de árbol de decisiones) y clasificar nuevas muestras de carne de res; v) el módulo genera una imagen en blanco y negro diferenciando las betas de grasa y cuantifica los pixeles correspondientes a la grasa.

### **3.3.3. Especificaciones técnicas o requerimientos del sistema**

Las especificaciones técnicas para el software se diseñaron en concordancia con los requerimientos operacionales formulados en la sección anterior y se detallan a continuación:

#### **3.3.3.1. Interfaces o ventanas**

- *Ventana principal.* Esta ventana permite cargar las imágenes y acceder a las funciones de análisis de hojas, queso, carne y caja de herramientas.
- *Ventana entrenamiento.* Permite extraer información para el entrenamiento de los clasificadores y/o modelado de relaciones mediante PLSR.
- *Ventana de opciones del sistema.* Esta ventana permite al usuario modificar las opciones del sistema: selección de método de clasificador, longitudes de onda para la imagen en pseudo RGB, selección del tipo de muestra a analizar, opciones generales y corrección espacial.

### 3.3.3.2. Restricciones de diseño

- *Estructura.* El sistema informático estará constituido por un sistema distribuido en diferentes módulos para el pre-procesamiento y análisis de imágenes.
- *Orientación de la aplicación.* El sistema se orientará al uso en computador, en diseño modular con arquitectura orientada a objetos<sup>3</sup>.
- *Interfaces de usuario.* Las interfaces de usuario serán orientadas a ventanas tipo Windows.
- *Interfaces Hardware.* El software se desarrollara considerando el uso de los periféricos comúnmente usados para introducción, selección y observación de información (teclado, ratón, pantalla).

### 3.3.4. Desarrollo de la arquitectura del sistema

En el desarrollo de la arquitectura del sistema se consideraron los cinco niveles comentados en la sección 3.2.2.2. A continuación se muestran los resultados de este desarrollo.

---

<sup>3</sup>La programación orientada a objetos es un paradigma de programación que usa objetos en sus interacciones, para diseñar aplicaciones y programas informáticos.

### 3.3.4.1. Nivel 1: Sistema del software

La arquitectura propuesta para el sistema del software de procesamiento y análisis, elaborada en base en los requerimientos operacionales y especificaciones técnicas, se esquematiza en la Figura 3. 4.

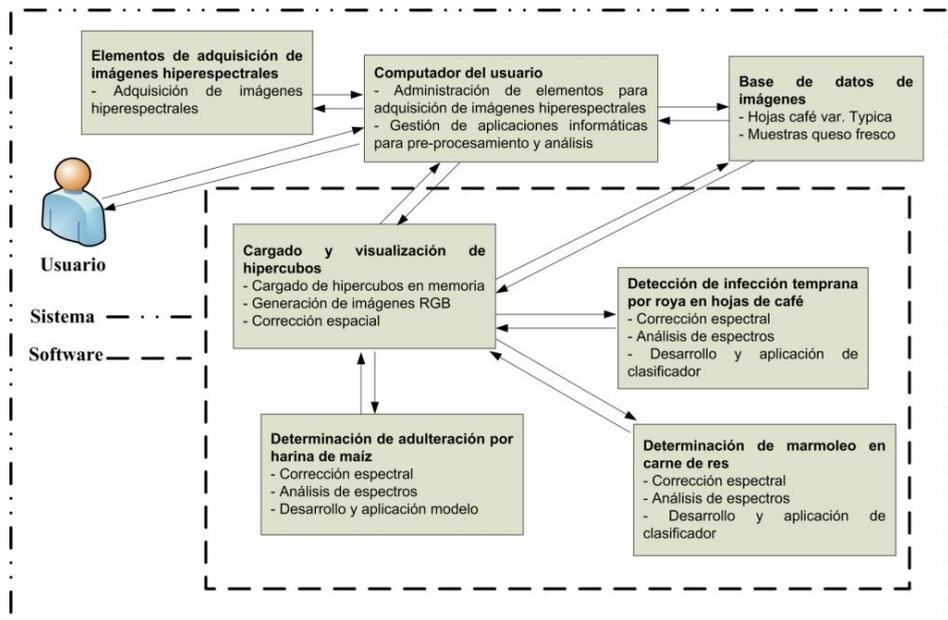


Figura 3. 4 Arquitectura del sistema

A este nivel se observa que el sistema requiere los siguientes subsistemas:

- Equipo para la adquisición de imágenes hiperespectrales
- Computador del usuario
- Base de datos de imágenes
- Software de procesamiento y análisis de imágenes

### 3.3.4.2. Nivel 2: Subsistemas

Como se deduce de la arquitectura del sistema (Figura 3. 4), el subsistema que necesita ser desarrollado es el software de pre-procesamiento y análisis de imágenes hiperespectrales, Figura 3. 5. Dicho software deberá incluir una interfaz que permita una adecuada comunicación con el usuario.

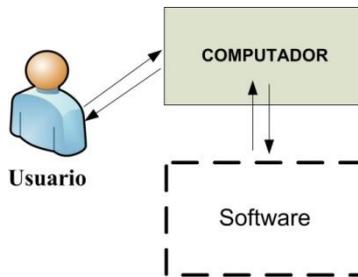


Figura 3. 5 Detalle del subsistema desarrollado

### 3.3.4.3. Nivel 3: Módulos

La labor de desarrollo de módulos en los elementos del sistema se ha limitado al software, ya que el acceso a la base de datos de imágenes hiperespectrales no requiere de software especializado.

Por tanto; el software se dividió en cuatro módulos (Figura 3. 4) los cuales se mencionan a continuación:

1. *Módulo de cargado y visualización de imágenes.*
2. *Módulo de detección temprana por roya en hojas de café.*
3. *Módulo de determinación de adulteración de queso fresco por harina de maíz.*
4. *Módulo de determinación de marmoleo en carne de res.*

Los detalles de las funciones realizadas por cada uno de los módulos se encuentran en la sección 3.3.2

#### 3.3.4.4. Nivel 4: Rutinas.

Las rutinas desarrolladas para cada módulo del software (Figura 3. 6) se describen en este subapartado.

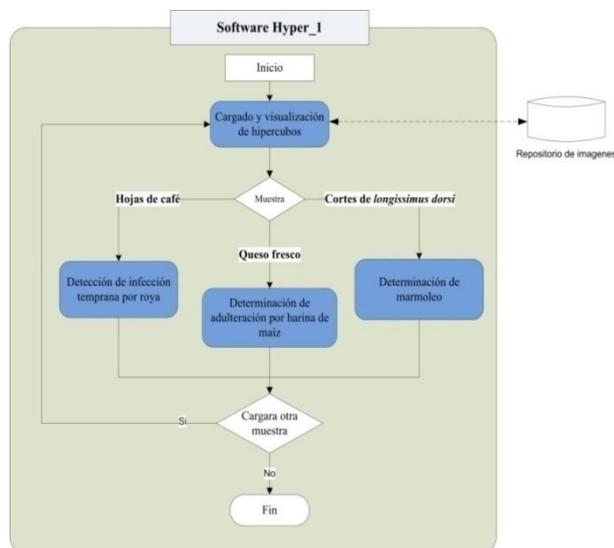


Figura 3. 6 Descripción del software en base a su estructura en módulos

I. Rutinas del módulo de cargado y visualización de hipercubos. Este módulo cuenta con dos rutinas (Figura 3. 7): Cargado de imagen en memoria y visualización RGB. La primera rutina se comunica con el repositorio de imágenes hiperespectrales y a la vez almacena en memoria operativa el hipercubo<sup>4</sup> para los posteriores módulos. La segunda rutina permite visualizar una imagen a color de la muestra; construyendo a partir de tres longitudes de onda preestablecidas una matriz tridimensional que simula una imagen RGB.

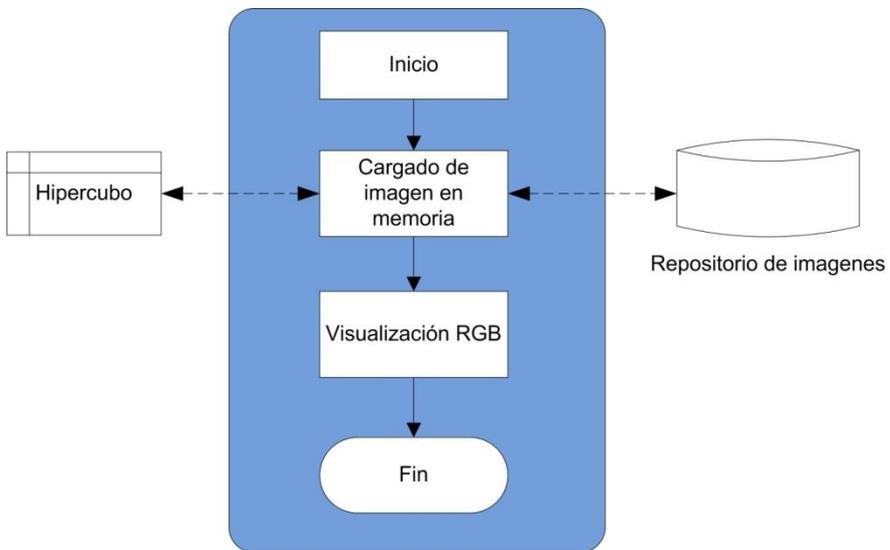


Figura 3. 7 Módulo cargado y visualización de hipercubos

- *Cargado de imagen en memoria*. En este módulo el usuario selecciona un archivo de cabecera \*.hdr; posteriormente, a partir de los datos contenidos en el archivo de cabecera, se carga la imagen a

<sup>4</sup> La definición de hipercubo se encuentra en el Capítulo I, sección 1.3

la memoria del computador mediante el comando *multibandread* de Matlab.

- *Visualización RGB*. La imagen en formato RGB <sup>5</sup> se crea concatenando en una matriz tridimensional las imágenes de intensidad a 600, 616 y 528 nm; capas asignada a las bandas de rojo, verde y azul respectivamente, Figura 3. 8.

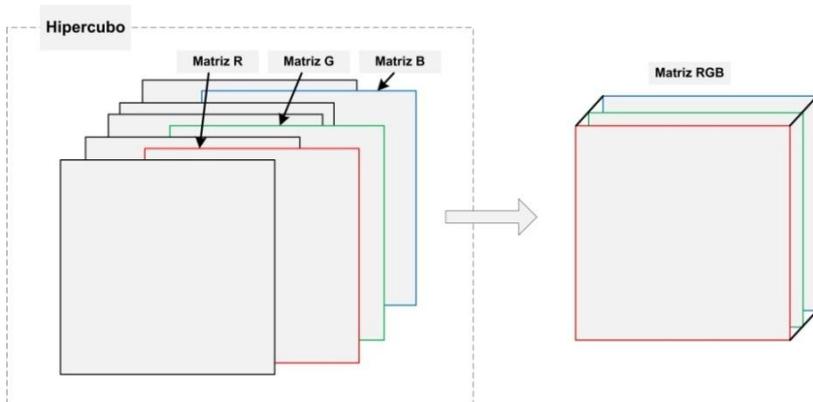


Figura 3. 8 Creación de imagen RGB

II. Rutinas del módulo detección de infección temprana por roya en hojas de café. Este módulo cuenta con seis rutinas (Figura 3. 9): Selección manual de ROIs (ver Capítulo 2, sección 2.7), selección automática de ROIs, extracción y corrección de perfiles espectrales, eliminación de perfiles anómalos, entrenamiento de clasificador, clasificación de ROIs.

---

<sup>5</sup> Este formato es pseudo RGB y se genera concatenando aquellas bandas que al unirse brindan dicha sensación.

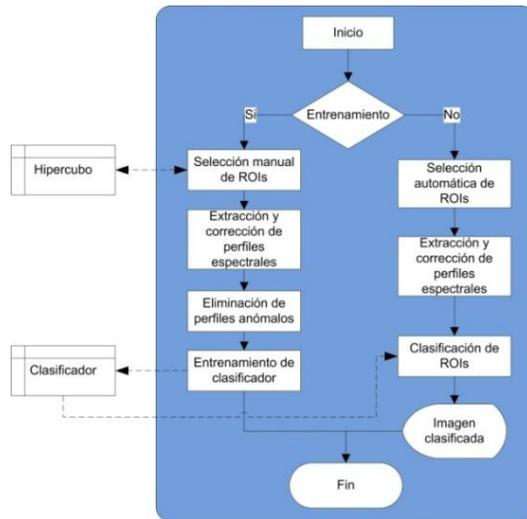


Figura 3. 9. Módulo detección de infección temprana por roya en hojas de café

- *Selección manual de ROIs.* El usuario selecciona la longitud de onda en la cual exista alto contraste entre las áreas con daño por roya y las áreas sanas; usando esta longitud de onda se visualiza una imagen de intensidad, sobre la cual el usuario dibuja una máscara de selección, mediante la función imfreehand, originando una ROI, Figura 3. 10.

Cada ROI es seleccionada para coincidir con una de las clases establecidas en la escala propuesta por la presente tesis y contiene los pixeles a partir de los cuales se extraerá la información espectral para las subrutinas posteriores.

Esta rutina se implementa para clasificar cinco niveles de daño por roya según la escala establecida en el Capítulo IV.

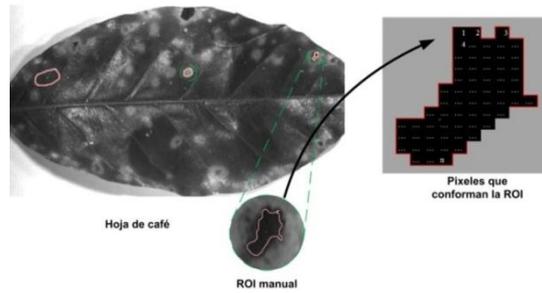


Figura 3. 10 Selección manual y estructura de una ROI

- *Selección automática de ROIs.* La selección de las ROIs en esta rutina, a diferencia de la anterior, se basa en segmentación por umbralizado, preestableciendo un valor umbral de reflectancia y longitud de onda a la que el fondo y la hoja muestren mayor contraste. El comando usado para segmentación es  $im2bw(im,tsh)$ ; donde  $im$  = imagen de intensidad y  $tsh$  = umbral

El resultado es una imagen binarizada<sup>6</sup>; conformándose la ROI por aquellos píxeles de color blanco.

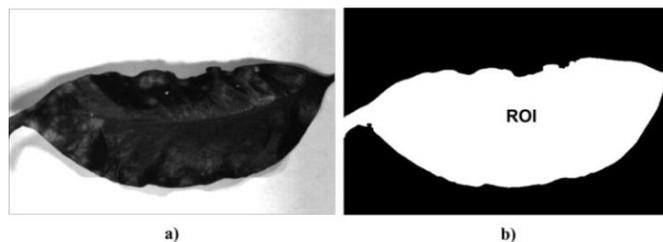


Figura 3.11 a) imagen de intensidad de hoja a 562 nm b) resultado de la segmentación por umbralizado

<sup>6</sup> Una imagen binarizada contiene valores en ceros (píxeles negros) o unos (píxeles blancos)

- *Extracción y corrección de perfiles espectrales.* A partir de los píxeles de la ROIs se extrajeron los perfiles espectrales, almacenándolos en una matriz denominada conjunto de espectros (CE), Tabla 3. 2; esta tabla CE contiene tanto los valores de reflectancia de cada pixel de la ROI a diferentes longitudes de onda, como la clase a la que esta pertenece y que se comentara en el Capítulo IV.

Tabla 3. 2 Matriz *CE*

Pixel	Reflectancia					Clases_p
	$\lambda_1$ (nm)	$\lambda_2$ (nm)	$\lambda_3$ (nm)	....	$\lambda_i$ (nm)	
1						
2						
3						
4						
5						
...						
n						

Este CE debe ser corregido a fin de eliminar la influencia de efectos no deseados: dispersión de la luz, ruido aleatorio, desplazamientos de línea de base y efectos de los factores externos no controlados. Un método usado para estas correcciones es el de Savitzky-Golay, el cual ha sido utilizado en el pre-procesado (corrección) de datos hiperespectrales en diferentes trabajos relacionados con el control de calidad en alimentos (Hu, Dong, Liu,

Opara y Chen, 2015; Kamruzzaman, Makino y Oshita, n.d; Kaneko y Funatsu, 2015; Ravikanth, Singh, Jayas y White, 2015). Esta aplicación informática corrige los espectros mediante el filtro de Savitzky-Golay; utilizando la función de Matlab *sgolayfilt* ( $x, k, f$ ) donde  $x$  es el vector de dato y,  $k$  es el orden que debe ser menor que el numero de datos  $f$ .

El resultado de la aplicación de este filtro sobre el perfil espectral de un pixel en un área sana de una hoja de café se muestra en la Figura 3. 12.

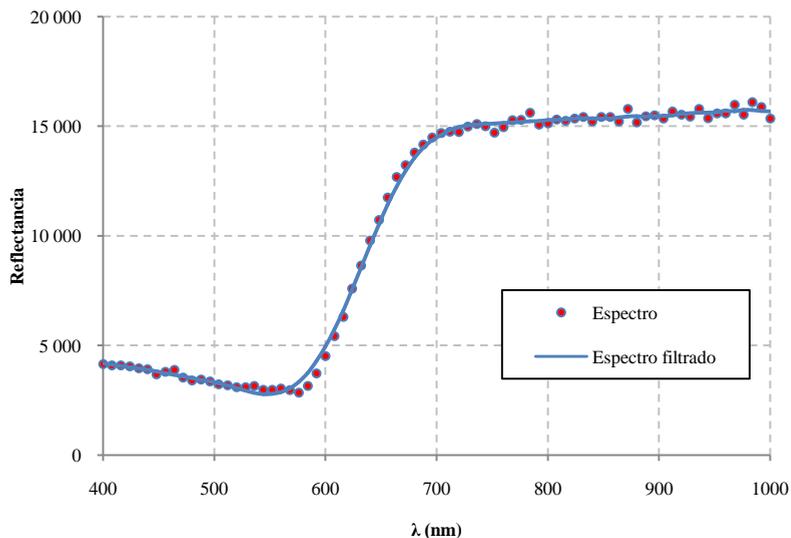


Figura 3. 12 Espectro suavizado por filtro Savitzky-Golay

Por tanto; luego de la aplicación de este filtro se obtiene un conjunto de espectros filtrados (CEF).

- 
- *Eliminación de perfiles anómalos.* Aquellos espectros con valores anómalos, debidos a errores durante la selección manual, son eliminados del CEF. Esta eliminación se realizó, como se muestra en la Figura 3. 13, seleccionando una longitud de onda ( $\lambda_i$ ) en la cual se extrajeron los valores de reflectancia de la totalidad de los espectros del CEF. Se dispusieron las reflectancias en un vector ( $R_\lambda$ ), a partir del cual se calculó el promedio ( $R_{\lambda-p}$ ) y la desviación estándar ( $R_{\lambda-dsv}$ ). Posteriormente se eliminaron del CEF aquellos espectros cuyo valor de reflectancia a dicha longitud de onda se encuentra fuera del rango [ $R_{\lambda-p} - R_{\lambda-dsv}$ ,  $R_{\lambda-p} + R_{\lambda-dsv}$ ], repitiendo la operación para todas las longitudes de onda que conforman el perfil espectral. El resultado es un nuevo conjunto de espectros no anómalos denominada  $CE_{na}$ .

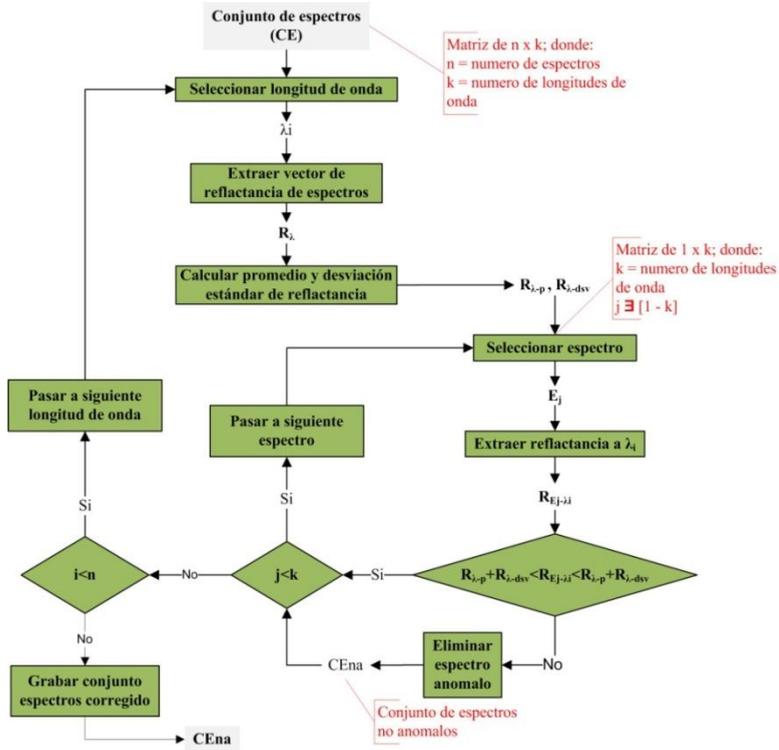


Figura 3. 13 Árbol de decisiones para la eliminación de espectros con valores anómalos

- *Entrenamiento de clasificador.* El modelo usado para la clasificación de áreas afectadas por roya fue el árbol de decisiones. Los árboles de decisiones, según Akkaş, Akin, Evren Çubukçu y Artuner (2015), son algunos de los clasificadores más poderosos y populares disponibles. Estos son modelos gráficos acíclicos que resuelven problemas de clasificación utilizando la representación simbólica, es decir, un gráfico de nodos de decisión que se conecta a través de los bordes (Figura 3. 14).

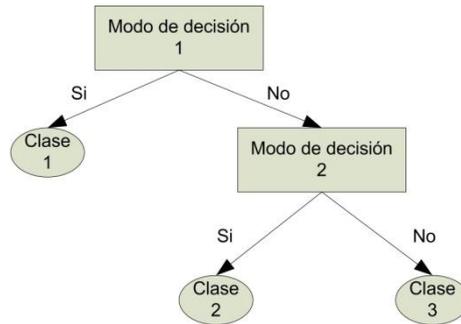


Figura 3. 14 Árbol de decisión consistente de nodos de decisión (nodos internos) y nodos hoja (nodos terminales)

Estos árboles, siguen la lógica y el razonamiento humano-diagrama de flujo, siendo capaces de modelar el problema de dominio como un conjunto de reglas de decisión. Los modelos resultantes de aplicar arboles de decisión son altamente accesibles a usuarios no familiarizados con los modelos de aprendizaje automático, encontrando una amplia gama de aplicaciones en áreas como negocios, fabricación, biología computacional, bioinformática, etc. (Akkaş y col., 2015; Bozkir y Sezer, 2011; Sok, Ooi y Kuang, 2015).

El entrenamiento de estos árboles de decisión tiene como objetivo obtener la máxima información y mínima entropía en los subconjuntos generados del árbol. Los datos son recogidos en un nodo raíz y se dividen en subconjuntos relativamente más

homogéneos llamados nodos internos, utilizando valores de características umbrales (Sok y col., 2015).

El entrenamiento del árbol de decisiones hace uso de la función  $classregtree(p,t)$ ; donde  $p$  es la matriz con las variables de entrada (perfil espectral) y  $t$  es la variable objetivo (clase). La estructura del resultado del árbol de decisiones, como grafo, se observa en la Figura 3. 15.

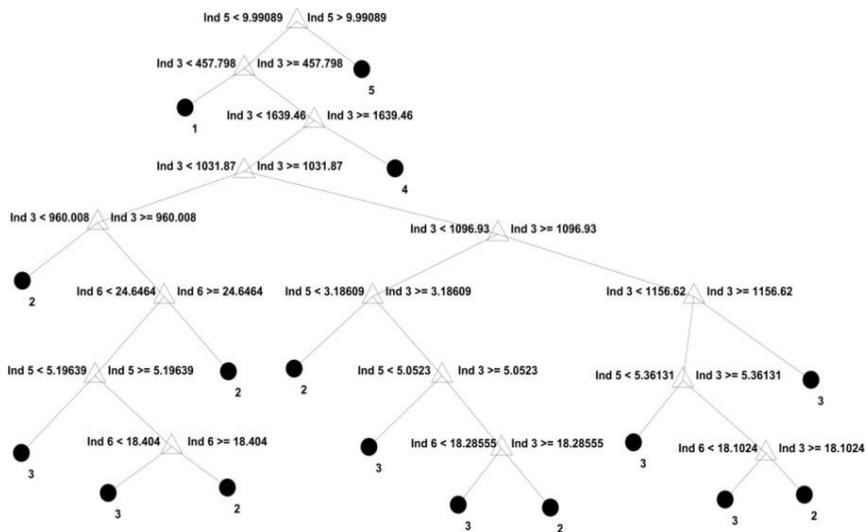


Figura 3. 15 Árbol de decisiones desarrollado para el análisis de infección por roya

- *Clasificación de ROIs.* La clasificación hace uso del árbol de decisión creado en la rutina anterior, mediante la función  $eval(t,X)$  en donde:  $t$  = árbol de decisión y  $X$  = perfil espectral.

III. Rutinas del módulo determinación de adulteración de queso fresco por harina de maíz. Este módulo cuenta con cinco rutinas (Figura 3. 16):

- i) selección automática de ROIs;
- ii) extracción y corrección de perfiles espectrales;
- iii) eliminación de perfiles anómalos;
- iv) desarrollo de modelo y
- v) determinación de contenido de almidón.

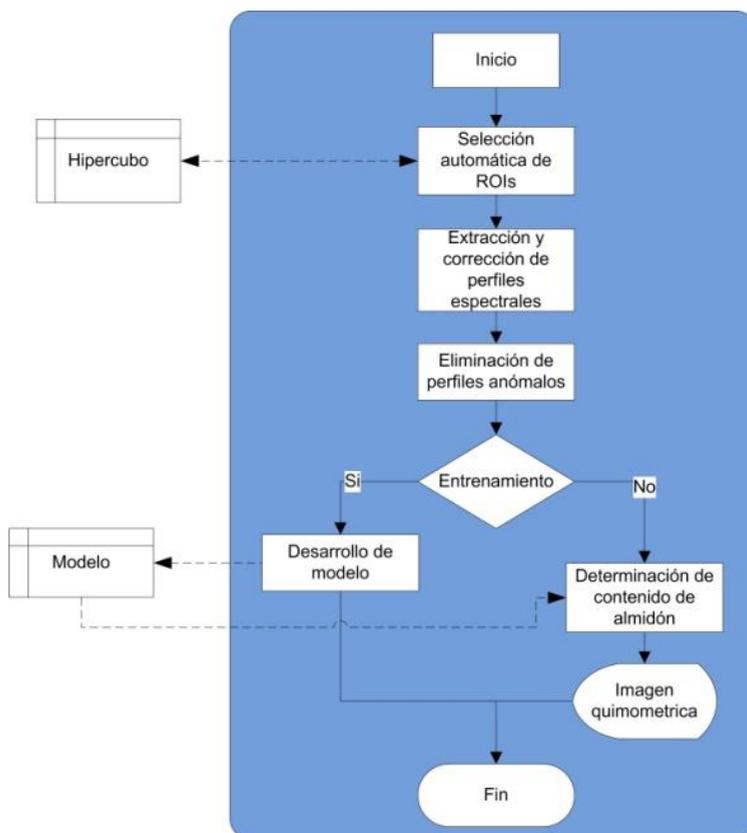


Figura 3. 16 Modulo detección de adulteración de queso fresco por harina de maíz

- *Selección automática de ROIs.* Esta rutina, al igual que la usada en el modulo de detección temprana de roya, hace uso de

segmentación por umbralizado para una imagen de intensidad a longitud de onda preestablecida.

El resultado de la aplicación de esta rutina en una imagen hiperspectral de la muestra de queso se observa en la Figura 3. 17.

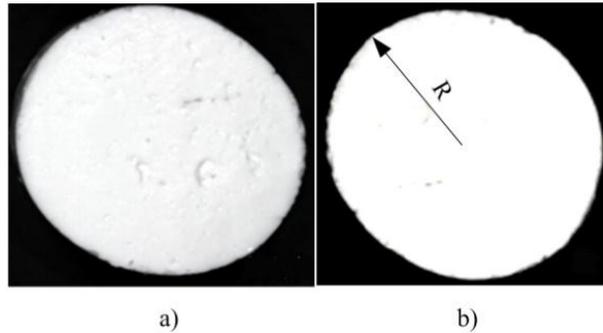


Figura 3. 17 Resultados de la segmentación de una imagen de queso a) imagen original b) imagen segmentada

Posteriormente; mediante la función *regionprops* se obtiene el radio de la muestra, con el cual se determina un área circular de radio igual a  $0.75R$ , la cual se constituye en la ROI.

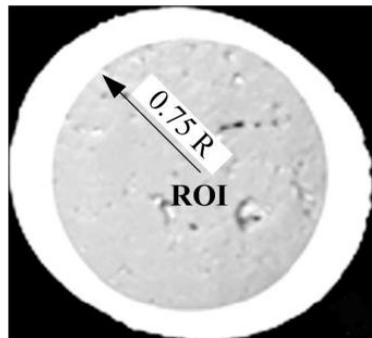


Figura 3. 18 Determinación de ROI

- 
- *Extracción y corrección de perfiles espectrales y eliminación de perfiles anómalos.* Ambas rutinas se realizaron mediante las rutinas desarrolladas en el módulo de detección temprana de roya.
  - *Desarrollo de modelo, determinación de contenido de almidón.* El modelo se desarrolló mediante el método de mínimos cuadrados parciales - PLSR. Este es un método estadístico que transforma las variables de entrada X en la salida Y. En nuestro caso, X consistió en los valores de reflectancia para diferentes longitudes de onda (patrones) en varias posiciones en las muestras, mientras que Y son los valores de contenido de almidón. El PLSR descompone tanto X como Y mediante proyecciones ortogonales, con la restricción que la descomposición describa como las variables cambian tanto como sea posible. Después de la descomposición de las variables, hay un paso de regresión en el que se utiliza la descomposición de X para calcular el valor de Y. Sin embargo; el PLSR genera problemas cuando existe alta multi-colinealidad en la matriz X, como en el caso de con los datos hiperespectrales que el número de longitud de onda es más que la de las muestras. En este caso se hace uso de el análisis de principales componentes PCA para reducir la dimensionalidad y extraer componentes o longitudes de onda

---

(Abdel y col., 2014; Dai y col., 2015; Dai, Cheng, Sun y Zeng, 2014; Fernandes y col., 2013). El modelo general es la ecuación 3.1;

$$Y = X * b + e... \text{ Ec. 3.2}$$

Dónde:

Y = Matriz de concentraciones de almidón en queso fresco.

X = Matriz de datos espectrales para cada muestra

b = Matriz de coeficientes de regresión

e = Matriz de información residual.

IV. Rutinas del módulo determinación de marmoleo en carne de res. Este modulo cuenta con las mismas rutinas utilizadas en el modelo para la detección temprana de roya en las hojas de café (Figura 3. 9); con algunas variantes que permiten que estas se ajusten al análisis concreto del marmoleo en carne de res. En las siguientes líneas se comentaran brevemente las diferencias en las rutinas para ambos módulos

- *Selección manual de ROIs.* La selección de ROIs se implementa para considerar tejido muscular (TM) y acumulaciones de grasa intramuscular (AGI), de acuerdo al Capítulo VI en el cual se aplica este sistema.

- Selección automática de ROIs. La ROI en este caso contempla el total del área segmentada mediante umbralizado; siguiendo el contorno de la muestra.
- Entrenamiento de clasificador. El entrenamiento del clasificador generó un árbol de decisión para la clasificación de las dos clases previamente comentadas (Figura 3. 19); este permite determinar que estas clases se pueden separar de acuerdo a la reflectancia relativa a 400 nanómetros.

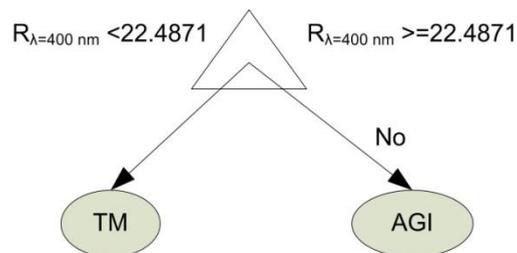


Figura 3. 19 Árbol de decisión para el análisis de marmoleo

- Clasificación de ROIs. Además de brindar una imagen clasificada se determina la clase de la carne de acuerdo a la norma japonesa de marmoleo.

### 3.3.5. Desarrollo de la aplicación informática

Una vez establecidas las especificaciones técnicas y la arquitectura del sistema, se procedió al desarrollo de la aplicación informática Hyper\_1.

Las ventanas que constituyen la interface de esta aplicación informática se muestran en la Figura 3. 20.

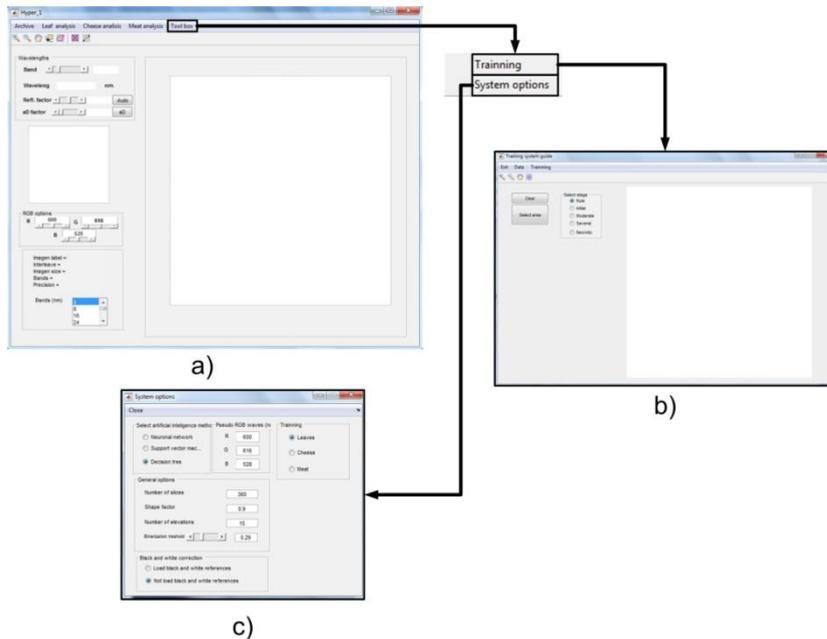


Figura 3. 20 Principales ventanas de la aplicación informática a) ventana principal b) ventana de entrenamiento c) ventana de opciones del sistema

En este software, la *ventana principal* posibilita el acceso a la ventana de *entrenamiento* y a la ventana de *opciones del sistema*; a través del uso del menú *toolbox*.

Los detalles de estas ventanas se comentan a continuación:

- *Ventana principal*. La ventana principal cuenta con los elementos mostrados en la Figura 3.21.

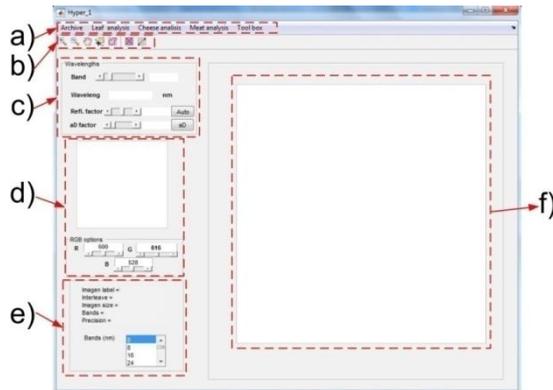


Figura 3. 21 a) menú principal b) barra de herramientas c) opciones de selección de longitud de onda d) área para visualizar imagen RGB e) área para mostrar información de hipercubo f) área de visualización de imagen de intensidad

a) Menú principal: este se divide en

- Archive: brinda opciones de cargado de imágenes, grabado de resultados y cierre de la aplicación.
- Leaf analysis: permite segmentación, mediante umbralizado, de imagen de intensidad de hoja de café y análisis de la imagen mediante el método descrito en sección 3.3.4.4 Ítem II.
- Cheese analysis: segmentación, mediante umbralizado, y análisis mediante el método PLSR, descrito en la sección 3.3.4.4 Ítem III.

- 
- Meat analysis: permite segmentación, mediante umbralizado, de imagen de intensidad de muestra de queso fresco y análisis de la imagen mediante el método de árbol de decisiones, descrito en la sección 3.3.4.4 Ítem IV.
  - Toolbox: estas opciones brindan la opción de acceder a los distintos análisis del sistema así como a la caja de herramientas
- b) Barra de herramientas: esta barra (Figura 3.22), además de contar con funciones comunes en el manejo de imágenes como aumento (zoom) y vista panorámica (pan), facilita la visualización y el análisis de información espectral mediante las siguientes funciones:
- Area: esta función extrae y muestra la información espectral de una ROI definida a mano alzada.
  - Spectra: permite extraer y visualizar la información espectral de un pixel.
  - Line: extrae y muestra los valores de reflectancia de una línea dibujada a mano alzada en una imagen de intensidad.

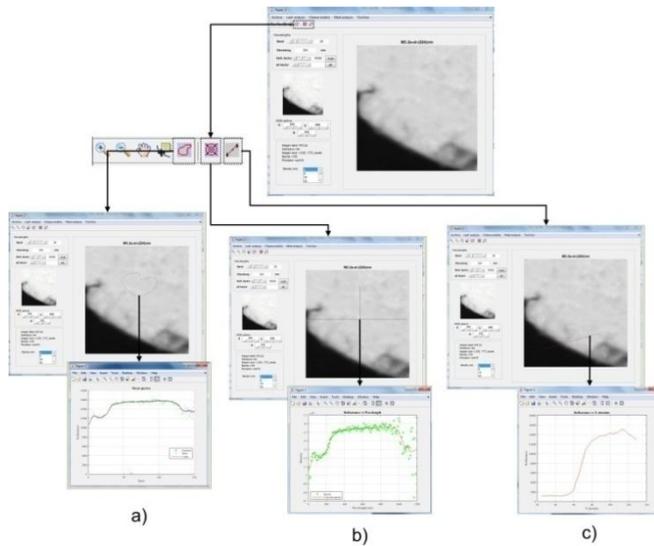


Figura 3. 22 Barra de herramientas de la aplicación Hyper\_1: a) Area b) Spectra  
c) Line

c) Opciones de selección de longitud de onda: permite seleccionar una longitud de onda y muestra la correspondiente imagen de intensidad.

d) Área para visualizar imagen RGB: en esta se muestra la imagen en pseudo RGB, mediante las longitudes de onda establecidas en los cuadros de texto R, G y B; además es posible cambiar las longitudes de onda

e) Área de información de hipercubo: en esta área se muestra la información del hipercubo, contenida en el archivo de cabecera \*.hdr.

- f) Área de visualización de imagen de intensidad: Esta es el área principal de visualización de esta ventana; se muestra tanto la imagen de intensidad como el resultado de los análisis de hojas, carne y queso.
- Ventana *entrenamiento*. Esta ventana facilita al usuario el entrenar los clasificadores (árboles de decisión, redes neuronal o maquinas soportadas en vectores) así como realizar regresiones mediante el método multivariado PLSR. Cada método se habilita previamente mediante la ventana de opciones del sistema. Los elementos que conforman esta ventana se muestran en la Figura 3. 23.

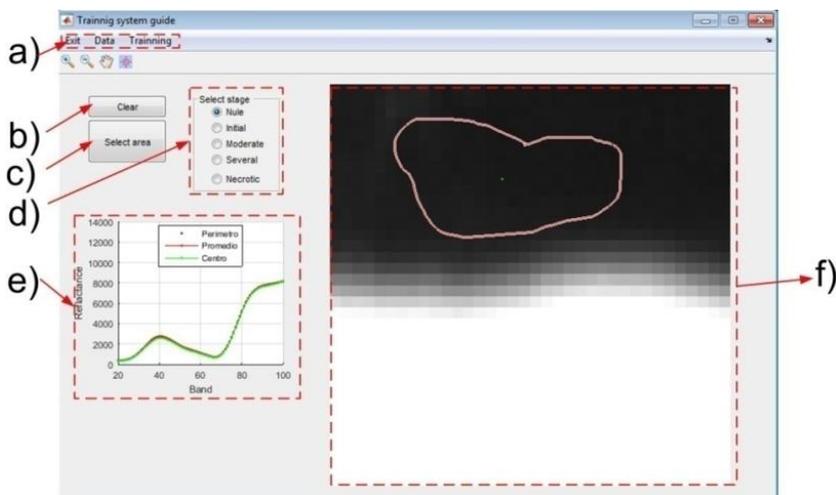


Figura 3. 23 a) Menú principal b) Botón Clear c) Botón selecta area d) Opciones select class e) Área para grafico f) Área de visualización de imagen de intensidad

Estos elementos se comentan brevemente a continuación:

- 
- a) Menú principal: el usuario mediante este menú puede salir de la ventana de entrenamiento, guardar la información en hoja Excel o realizar el entrenamiento / elaboración de regresión PLSR.
- b) Botón clear: este botón limpia el área de visualización de imagen de intensidad, así como de la memoria, la ROI seleccionada manualmente.
- c) Botón select area: este botón permite seleccionar manualmente la ROI; deshabilitándose en caso de requerirse selección automática, como en el análisis de quesos adulterados.
- d) Opciones select class: permite determinar la clase a la que pertenece la ROI; estas se actualizan según sea la muestra de hojas o carne y se deshabilita en el caso del queso fresco.
- e) Área para gráfico: en esta área se grafican el perfil promedio y los perfiles del perímetro y del centro geométrico de la ROI.
- f) Área de visualización de imagen de intensidad: en esta área se muestra la imagen de intensidad de acuerdo a la longitud de onda previamente seleccionada.

- Ventana *opciones del sistema*. Esta ventana se establecen los parámetros que las distintas funciones utilizaran en la aplicación informática. Los elementos que conforman esta ventana se muestran en la Figura 3. 24.

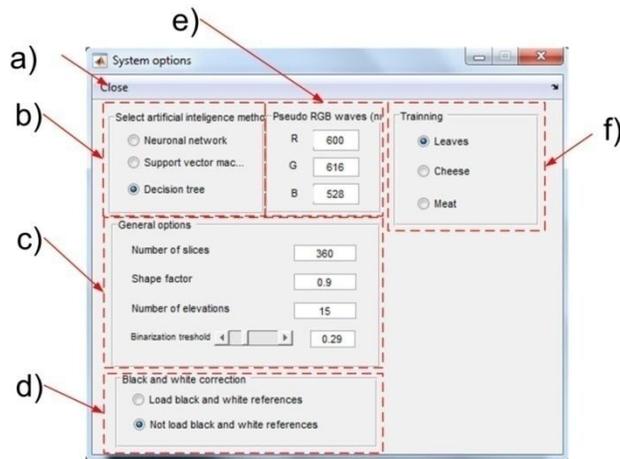


Figura 3. 24 a) Botón close b) Opciones de método de inteligencia artificial c) Opciones generales d) Opciones de corrección espacial e) Longitudes de onda para pseudo RGB f) Opciones de entrenamiento

En las siguientes líneas se comentan brevemente cada uno de estos elementos:

a) Botón close: este botón cierra la aplicación y activa la actualización de los parámetros del sistema.

b) Opciones de método de inteligencia artificial: el sistema se ha provisto de la capacidad de utilizar redes neuronales, arboles de decisión y maquinas soportadas en vectores, para los procesos de

clasificación; sin embargo, por la velocidad de cálculo de los árboles de decisión estos han sido los establecidos por defecto para los procesos de clasificación.

c) Opciones generales: mediante estas opciones se modifican los parámetros comunes para el mejoramiento y segmentación de imágenes.

d) Opciones de corrección espacial: esta opción posibilita corregir hipercubos mediante imágenes de referencia (blanco y negro) en caso que no se haya realizado la corrección en el software de adquisición.

e) Longitudes de onda para pseudo RGB: en estos cuadros de texto se pueden preestablecer las longitudes de onda a utilizar en la construcción de la imagen en pseudo RGB

f) Opciones de entrenamiento: mediante estas opciones se establece el tipo de muestra en estudio; definiendo así el comportamiento de la ventana de entrenamiento y sus elementos, adecuándose a las necesidades para cada tipo de muestra.

### **3.4. Conclusiones**

1) Se han desarrollado herramientas informáticas para el control de calidad mediante técnicas de análisis de imágenes hiperespectrales, que se aplican de forma específica a los tres casos de estudio de la presente tesis doctoral.

2) Las herramientas desarrolladas se han implementado en un software que permite fácil uso de las mismas. El software es totalmente compatible con el sistema de adquisición de imágenes desarrollado y descrito en el capítulo anterior.

3) El uso del software permite realizar de forma automática diferentes operaciones de procesado y análisis de imagen, lo que facilita el trabajo del usuario disminuyendo errores y tiempo de análisis.

4) Una versión avanzada del software podría ser patentada y transferida a la industria, en una fase posterior a la realización de esta tesis doctoral. Dicho software podría ser diseñado de tal forma que pudiera incluir de forma progresiva nuevas herramientas útiles en el control de calidad de otros procesos agroalimentarios.

---

**Referencias bibliográficas**

- Abdel, E., Mutanga, O., Odindi, J., Adam, E., Odindo, A. y Ismail, R. (2014). A comparison of partial least squares (PLS) and sparse {PLS} regressions for predicting yield of Swiss chard grown under different irrigation water sources using hyperspectral data. *Computers and Electronics in Agriculture*, 106, 11 – 19.
- Akkaş, E., Akin, L., Evren Çubukçu, H., y Artuner, H. (2015). Application of Decision Tree Algorithm for classification and identification of natural minerals using SEM–EDS. *Computers and Geosciences*, 80, 38–48.
- Amigo, J., Martí, I., y Gowen, A. (2013). Hyperspectral Imaging and Chemometrics: A Perfect Combination for the Analysis of Food Structure, Composition and Quality. In *Data Handling in Science and Technology*, 28, 343–369.
- Barbedo, J., Tibola, C., y Fernandes, J. (2015). Detecting Fusarium head blight in wheat kernels using hyperspectral imaging. *Biosystems Engineering*, 131, 65 – 76.
- Bozkir, A. y Sezer, E. (2011). Predicting food demand in food courts by decision tree approaches. *Procedia Computer Science*, 3, 759–763.

- 
- Brosnan, T. y Sun, D. (2002). Inspection and grading of agricultural and food products by computer vision systems - a review. *Computers and Electronics in Agriculture*, 36, 193–2013.
  - Dai, Q., Cheng, J., Sun, D., Pu, H., Zeng, X. y Xiong, Z. (2015). Potential of visible/near-infrared hyperspectral imaging for rapid detection of freshness in unfrozen and frozen prawns. *Journal of Food Engineering*, 149, 97 – 104.
  - Dai, Q., Cheng, J., Sun, D. y Zeng, X. (2014). Potential of hyperspectral imaging for non-invasive determination of mechanical properties of prawn (*Metapenaeus ensis*). *Journal of Food Engineering*, 136, 64 – 72.
  - Dobre, T. y Marcano, J. (2007). *Chemical Engineering: Modeling, Simulation and Similitude*. John Wiley and Sons.
  - Elmasry, G., Barbin, D., Sun, D. y Allen, P. (2012). Meat quality evaluation by hyperspectral imaging technique: an overview. *Food Science and Nutrition*, 52, 689–711.
  - Everard, C., Kim, M. y Lee, H. (2014). A comparison of hyperspectral reflectance and fluorescence imaging techniques for detection of contaminants on spinach leaves. *Journal of Food Engineering*, 143, 139 – 145.

- 
- Fairley, R. (2011). *Managing and leading software projects*. John Wiley and Sons.
  - Fernandes, A., Lousada, J., Morais, J., Xavier, J., Pereira, J. y Melo-Pinto, P. (2013). Comparison between neural networks and partial least squares for intra-growth ring wood density measurement with hyperspectral imaging. *Computers and Electronics in Agriculture*, 94, 71 – 81.
  - Gómez-Sanchis, J., Gómez-Chova, L., Aleixos, N., Camps-Valls, G., Montesinos-Herrero, C., Moltó, E. y Blasco, J. (2008). Hyperspectral system for early detection of rottenness caused by *penicilliumdigitatum* in mandarins. *Journal of Food Engineering*, 89(1), 80–86.
  - Hu, M., Dong, Q., Liu, B., Opara, U. y Chen, L. (2015). Estimating blueberry mechanical properties based on random frog selected hyperspectral data. *Postharvest Biology and Technology*, 106, 1–10.
  - Jacobson, I., Booch, G., Rumbaugh, J., Rumbaugh, J. y Booch, G. (1999). *The unified software development process (Vol. 1)*. Addison-wesley Reading.
  - Kamruzzaman, M., Makino, Y. y Oshita, S. (In Press). Rapid and non-destructive detection of chicken adulteration in minced beef using

---

visible near-infrared hyperspectral imaging and machine learning. *Journal of Food Engineering*.

- Kaneko, H., y Funatsu, K. (2015). Classification of drug tablets using hyperspectral imaging and wavelength selection with a GAWLS method modified for classification. *International Journal of Pharmaceutics*, 491(1–2), 130–135.
- McConnell, S. (2004). *Code Complete*. Microsoft Press.
- Mishra, P., Cordella, C., Rutledge, D., Barreiro, P., Roger, J. y Diezma, B. (2016). Application of independent components analysis with the {JADE} algorithm and {NIR} hyperspectral imaging for revealing food adulteration. *Journal of Food Engineering*, 168, 7 – 15.
- Munson, J. (2005). *Software specification and design: an engineering approach*. CRC Press.
- Naganathan, G., Cluff, K., Samal, A., Calkins, C., Jones, D., Lorenzen, C. y Subbiah, J. (2015a). A prototype on-line {AOTF} hyperspectral image acquisition system for tenderness assessment of beef carcasses. *Journal of Food Engineering*, 154, 1 – 9.
- Naganathan, G., Cluff, K., Samal, A., Calkins, C., Jones, D., Lorenzen, C. y Subbiah, J. (2015b). Hyperspectral imaging of ribeye

- 
- muscle on hanging beef carcasses for tenderness assessment. *Computers and Electronics in Agriculture*, 116, 55 – 64.
- Ravikanth, L., Singh, C., Jayas, D. y White, N. (2015). Classification of contaminants from wheat using near-infrared hyperspectral imaging. *Biosystems Engineering*, 135, 73–86.
  - Rud, R., Shoshany, M., y Alchanatis, V. (2013). Spatial–spectral processing strategies for detection of salinity effects in cauliflower, aubergine and kohlrabi. *Biosystems Engineering*, 114(4), 384 – 396.
  - Simko, I., Jimenez-Berni, J. y Furbank, R. (2015). Detection of decay in fresh-cut lettuce using hyperspectral imaging and chlorophyll fluorescence imaging. *Postharvest Biology and Technology*, 106, 44 – 52.
  - Sok, H., Ooi, M., y Kuang, Y. (2015). Sparse alternating decision tree. *Pattern Recognition Letters*, 60–61, 57–64.
  - Sun, D. (2010). *Hiperspectral Imaging for Food Quality Analisis And Control*. San Diego - USA.: Elsevier

---

---

**4. Aplicación de la técnica de Imágenes hiperespectrales a la detección temprana de roya (*Hemileia vastatrix* Berkeley y *Broome*) en hojas de café arábica (*Coffea arabica* L.) var. *Typica***

---

---

#### 4.1. Introducción

El café es un producto cultivado en países tropicales, principalmente en aquellos en vías desarrollo; constituyéndose en el primer rubro de exportación agrícola y primera fuente generadora de divisas después del petróleo, además muestra perspectivas de desarrollo en el mercado internacional (OEEE, 2013; Panhuysen y Pierrot, 2014). En este mercado el Perú viene incrementado su participación y sus principales consumidores se muestran en la Figura 4. 1 (Escalante, 2014).

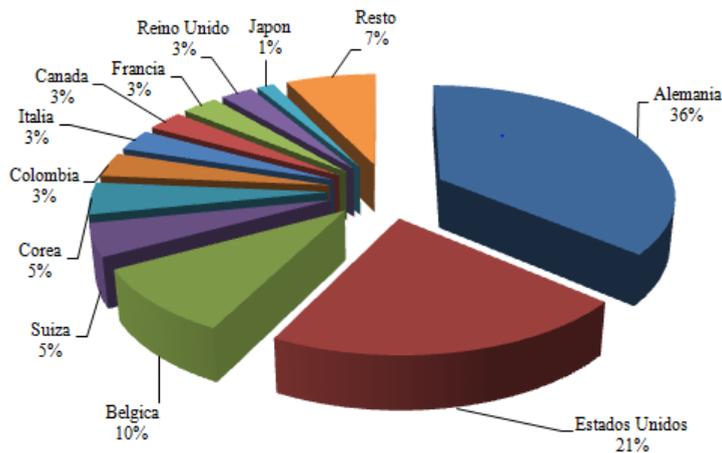


Figura 4. 1 Principales países de destino de las exportaciones de café  
Fuente: Escalante (2014).

Mención especial merece la participación del Perú en el sector de productos orgánicos alcanzando, en el año 2011, el primer lugar en producción y exportación a nivel mundial (Huamán y col., 2014)

En cuanto a la producción del café peruano, hasta el año 2001, la producción nacional no superó las 200 mil toneladas (Figura 4. 2). Sin embargo; del 2001 al 2010, se produce un crecimiento oscilante, acompañada de de la producción y rendimiento por hectárea (OEEE, 2015).

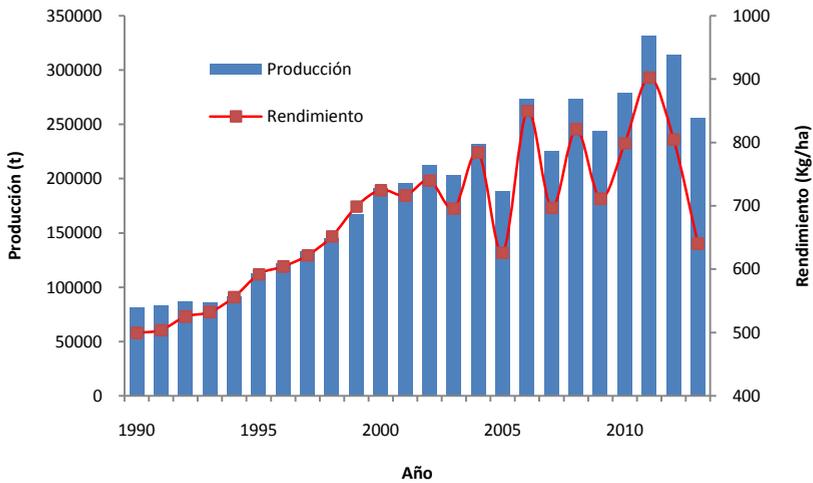


Figura 4. 2 Producción y rendimiento del café en Perú  
Fuente: OEEE (2015)

Graficando la variación del rendimiento del café, Figura 4. 3, se observa que a partir del 2009 se produce una reducción sostenida en la variación anual del rendimiento por hectárea, alcanzado la cifra más baja en los últimos 25 años, declinando en este año en 20.5 %; explicada esta cifra en gran parte por los efectos de la roya amarilla, que daña a las hojas del cafeto (Alzate, 2015; Guerra y Welchez, 2013).

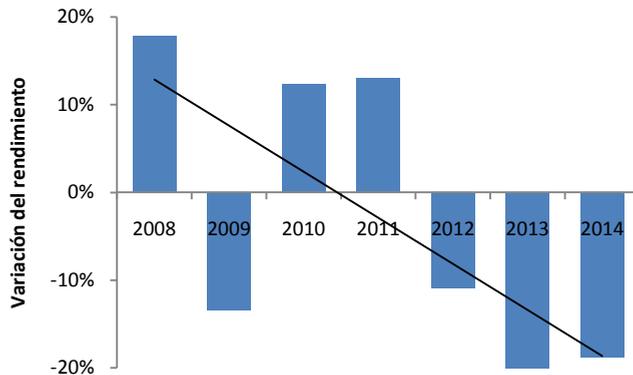


Figura 4. 3 Variación porcentual del rendimiento por hectárea en del cultivo de café  
Fuente: OEEE (2015)

## 4.2. Planta de café

El café pertenece a la familia de las rubiáceas (*Rubiaceae*), grupo que engloba unos 500 géneros y más de 6.000 especies, la mayoría árboles y arbustos tropicales (Rojo Jiménez, Pérez-Urria Carril, Rojo Jiménez, y Pérez-Urria Carril, 2014). Es originario de África tropical, señalándose a Etiopía, Sudán, Kenia, Guinea o Mozambique como posibles centros de origen; aún así por consenso casi unánime el café se originó en forma silvestre, conocida como Arábica, en el altiplano de Abisinia (actual Etiopia), circula una serie de leyendas respecto al descubrimiento de su uso como bebida (Arvy, Gallouin, Ubillos y Montalbán, 2007; Gotteland y de Pablo, 2007; Guerra y Welchez, 2013).

En cuanto a especies las dos más importantes, desde el punto de vista económico, son *Coffea arabica* L. (café arábica) y *Coffea canephora* Pierre ex Froehner (café robusta), abastecen el 70% y 30% respectivamente del café que se consume en el mundo (Alzate, 2015); también existe otra especie conocida pero cultivada en menor escala denominada *Coffea liberica* (café libérica) (Alzate, 2015; Rojo y col., 2014). Las características más relevantes de estas especies de café se muestran en la Tabla 4. 1.

Tabla 4. 1 Características relevantes de *C. arabica* y *C. canephora*

Especies	Variedad	Origen	Principales características <sup>7</sup>
<i>Coffea arabica</i>	<i>Typica</i>	Probablemente Yemen	<ul style="list-style-type: none"> <li>- Hábito de crecimiento: en posición vertical, vigoroso</li> <li>- Resistencia a la roya: muy susceptible</li> <li>- La calidad de tasa: excelente</li> </ul>
<i>Coffea arabica</i>	<i>Java</i>	Indonesia	<ul style="list-style-type: none"> <li>- Hábito de crecimiento: en posición vertical, vigoroso</li> <li>- Resistencia a la roya: muy susceptible</li> <li>- La calidad de tasa: excelente</li> </ul>
<i>Coffea arabica</i>	<i>Bourbon</i>	Brazil	<ul style="list-style-type: none"> <li>- Hábito de crecimiento: semienano, follaje denso.</li> <li>- Resistencia a la roya: muy susceptible</li> <li>- La calidad de la copa: pobre</li> </ul>
<i>Coffea canephora</i>	<i>Kouilouensis</i> <i>or conillon</i>	Brazil	<ul style="list-style-type: none"> <li>- Hábito de crecimiento: árbol de altura</li> <li>- Resistencia a la roya: resistentes / tolerantes</li> <li>- La calidad de la copa: reducido nivel de tasa</li> </ul>

Fuente: A partir de Farah y Dos Santos (2015)

<sup>7</sup> Acerca de la roya como enfermedad se tratara en las siguientes páginas.

### 4.3. Generalidades de la enfermedad por roya

#### a. Distribución y origen de la roya

La roya es causada por el hongo *Hemileia vastatrix* Berk. y Br. (*Basidiomycota, Uredinales*) y es una de las principales enfermedades del café, extendiéndose a prácticamente todos los países productores de café, Figura 4. 4 (Cristancho, Rozo, Escobar, Rivillas y Gaitan, 2013; SAGARPA, 2013).

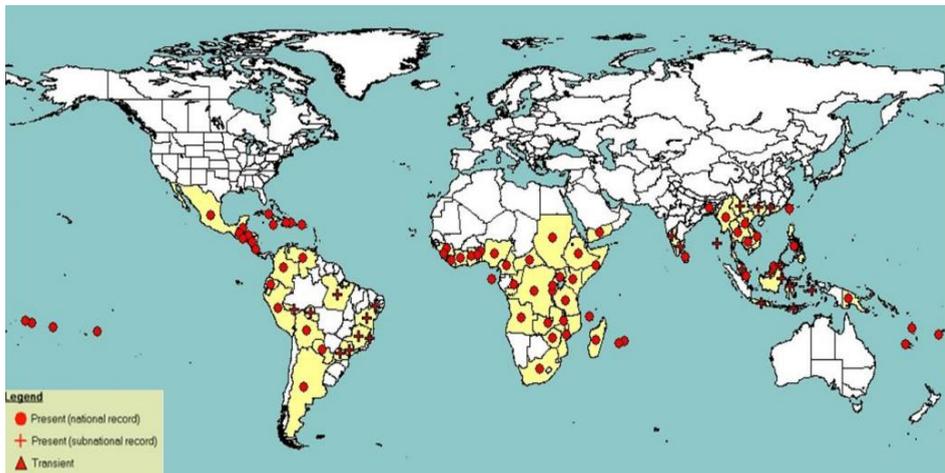


Figura 4. 4 Distribución mundial de *H. vastatrix*  
Fuente: SAGARPA (2013).

Esta enfermedad fue identificada por primera vez en Sri Lanka en la segunda mitad del siglo XIX y el primer reporte de esta enfermedad en Latinoamérica data de 1970 en Brasil; esto se origino cuando fue

introducido en América del Sur el cultivo de *C. arabica*, de reducida variabilidad genética, provocando que la mayoría de las plantaciones se perdieran a causa de la enfermedad y tuvieran que ser sustituidas por nuevas variedades resistentes como la catimor, mismas que son de reducida calidad en tasa. En cuanto a Perú la roya amarilla ingresa al Perú el año 1979, ocasionando grandes pérdidas en la zona de Satipo (Márquez-Dávila, Arévalo y Gonzáles, 2014; Rivillas-Osorio, Serna-Giraldo, Cristancho-Ardila y Gaitán-Bustamante, 2011; Rojo y col., 2014)

#### **b. Impacto económico**

La roya amarilla del café es la plaga más destructiva que afecta al cafeto a nivel mundial. Provoca la caída prematura de las hojas, propiciando una reducción de la capacidad fotosintética de la planta, así como el debilitamiento de los árboles enfermos, y en infecciones severas, puede ocasionar la muerte regresiva en ramas y árboles (Jackson, Skillman, y Vandermeer, 2012; Santos, Carrión, Tirabanti, y Arévalo, 2014).

Para aquellos países cuyas economías se basan en un alto porcentaje en las exportaciones del café, tales como el Perú (Panhuysen y Pierrot, 2014), una mínima reducción en el rendimiento de la planta o un ligero

aumento en los costos de producción por efecto de la roya, puede tener un gran impacto socio-económico (Márquez-Dávila y col., 2014). Según Santos, Carrión, Tirabanti, y Arévalo (2014), en el Perú el Servicio Nacional de Sanidad Agraria (SENASA) revela que la plaga de roya afecta al 43 % del área cafetalera peruana y entre las zonas más afectadas están las regiones de San Martín, Puno, Pasco, Amazonas, Junín, Cajamarca y el valle de los ríos Apurímac y Ene.

### **c. Desarrollo de la infección por roya**

La infección por roya comienza con los síntomas de la enfermedad, manchas cloróticas - pálidas, apareciendo en el envés de las hojas y que con el tiempo van aumentando de tamaño y uniéndose para formar las características manchas amarillas o naranja, con presencia de polvo fino amarillo (esporas del hongo) y ciclo se muestra en la Figura 4. 5 (Lagos, 2014; Rivillas-Osorio y col., 2011).

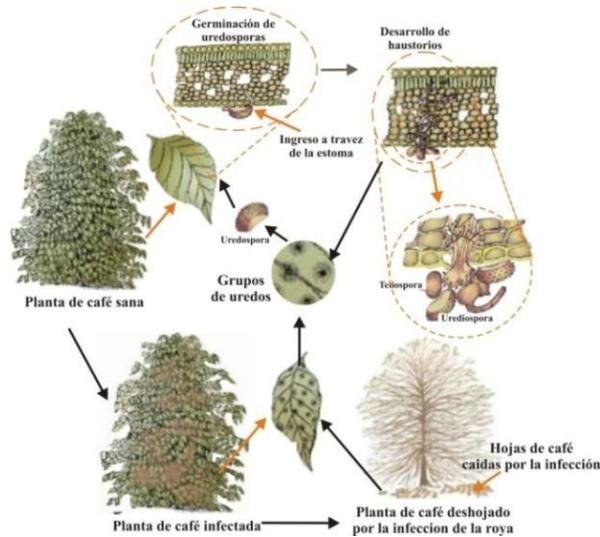


Figura 4. 5 Ciclo biológico de la infección por roya  
Fuente: Lagos, 2014

La germinación de esporas requiere: presencia de agua libre por al menos 6 horas, temperaturas entre 21 - 25 °C y condiciones de obscuridad. Puede ser inhibida por la luz o cuando se evapora el agua de la hoja, al afectar el crecimiento de los tubos germinativos. Sin embargo; luego de germinar, el hongo penetra en las hojas a través de las aberturas naturales (estomas) situadas en el envés de las hojas maduras (Guerra Burgos y Welchez Arita, 2013; Rayner, 1961) Una vez que ha penetrado al interior de la hoja, el hongo desarrolla unas estructuras denominadas haustorios, los cuales entran en contacto con las células de la planta y con éstos extraen los nutrientes para su crecimiento. Luego de transcurridos 30 días, desde la colonización, se diferencian estructuras llamadas soros,

encargadas de producir nuevas uredosporas. El tiempo transcurrido desde la infección hasta la producción de esporas se denomina periodo de latencia, para zonas tropicales, el periodo de latencia puede fluctuar entre 34 y 37 días al sol y entre 31 y 35 días a la sombra y su curva de progreso puede apreciarse en la Figura 4. 6 (Avelino y Rivas, 2013; Rivillas-Osorio y col., 2011; SAGARPA, 2013).

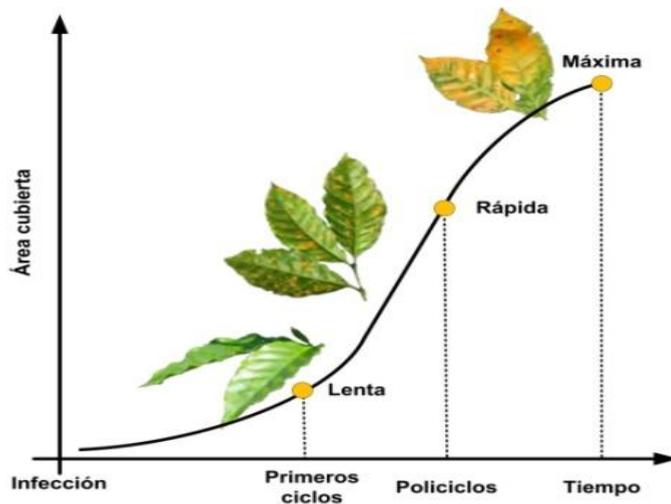


Figura 4. 6 Curva de progreso de la enfermedad por roya.  
Fuente: a partir de Rivillas-Osorio y col. (2011).

#### **d. Factores que propician el desarrollo de la infección por roya**

El desarrollo de una epidemia de roya y el posterior progreso de la enfermedad dependen de la ocurrencia simultánea de cuatro factores, Figura 4. 7 (Rivillas-Osorio y col., 2011; SAGARPA, 2013)

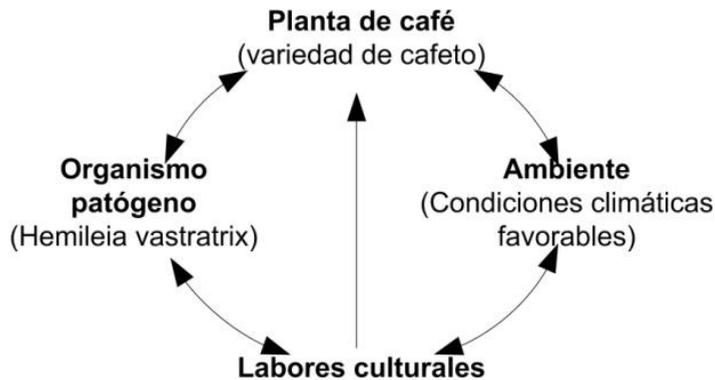


Figura 4. 7 Interrelación de factores que interactúan para una epidemia de roya

Fuente: Adaptado de Rivillas-Osorio y col. (2011)

A continuación se detallan algunos de los factores involucrados en el desarrollo de la infección por roya (Lagos, 2014; Rivillas-Osorio y col., 2011; SAGARPA, 2013):

**La planta.-** la especie *Coffea arabica* y sus variedades Típica, Borbón y Caturra, es carente de resistencia genética a la roya; presentándose fuertes ataques de la enfermedad en sus plantaciones. La especie *C. canephora*, cuenta con relativa tolerancia al ataque de la roya. Otros factores a considerar son el estado fisiológico de la planta, desarrollo de raíces, ataque de nematodos o palomilla, malformaciones desde el almácigo, estrés por exceso de agua en el suelo o deficiencias nutricionales hacen que las plantas sean más propensas a padecer fuertes ataques de roya.

**El patógeno.-** La roya del cafeto se especializa en parasitar células vegetales vivas; lo que implica requerimientos nutricionales muy especiales, haciendo de este un parásito obligado, incapaz de sobrevivir en suelo o en material vegetal inerte.

**Condiciones climáticas.-** El hongo necesita condiciones climáticas muy particulares para parasitar las hojas de la planta de café. En especial, requiere de la salpicadura de la lluvia, temperaturas entre 16 y 28 °C y bajo brillo solar.

**Manejo agronómico.-** El manejo agronómico juega un papel importante en la aparición y desarrollo de la enfermedad; entre las principales labores agronómicas que favorecen o no el crecimiento de la roya se tiene:

- Manejo de malezas. Estas además de competir con el café por los nutrientes del suelo, generan condiciones de sombrío y alta humedad en plantaciones de café menores de 24 meses.
- Fertilización. La reducida o escasa fertilización afecta principalmente a los cafetales bajo plena exposición solar.
- Sombra excesiva. Favorece una humedad relativa alta constante y estimula el incremento del área foliar y la vida media de las hojas

- Excesiva densidades. Crea auto sombreado, aumentando la competencia entre plantas por nutrientes y ofrece una mayor interceptación de esporas.
- Aplicaciones tardía de fungicidas, fuera de la epidemia, sub dosificadas o sobre dosificadas, con equipos inadecuados o sin calibrar, con boquillas de alta descarga o desgastadas, con la utilización de aguas contaminadas o duras, y con recorridos en los lotes que no permiten un cubrimiento completo del follaje de las plantas o usando mezclas con otros productos que reducen la efectividad biológica de los fungicidas.

#### **4.4. Escalas de medición del daño por roya**

La medición del daño por roya se evalúa determinando tanto el avance como la severidad de la enfermedad; el avance se entiende como el porcentaje de área foliar que presenta signos de roya (PAFR) y la severidad como la evolución de las áreas infectadas, estas inicialmente se presentan como pequeñas manchas cloróticas y crecen hasta convertirse en lesiones necróticas (Alzate, 2015; Lagos, 2014).

Diversos investigadores han propuesto escalas para medir el daño por roya; como Kushalappa y Chávez quienes en 1978 presentaron una

escala diagramática para medir tanto el avance como la severidad. Esta escala se basa en patrones de área foliar y tamaño de la lesión que el evaluador utiliza para comparar las lesiones en la hoja causadas por la roya del café durante el desarrollo de la enfermedad, Figura 4. 8.

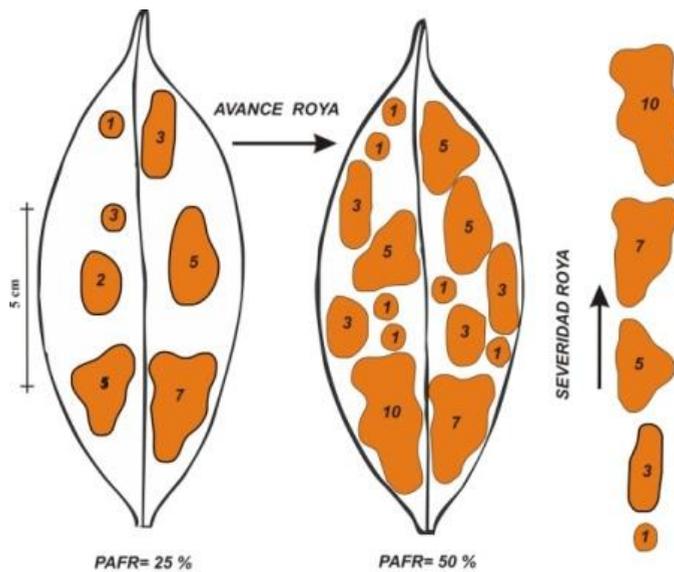


Figura 4. 8 Escala de Kushalappa y Chávez para evaluación del avance y severidad de la roya

Fuente: a partir de Santacre, Reyes y Oseguera (1983)

Capucho y col. (2011) proponen el empleo de un diagrama de área estándar (Figura 4. 9), la cual cuenta con seis niveles para el avance del daño basados en el PAFR, 2-5, 5, 10, 20, 40 y 80 %, como referencia de comparación y estimación más precisa del avance de la enfermedad.

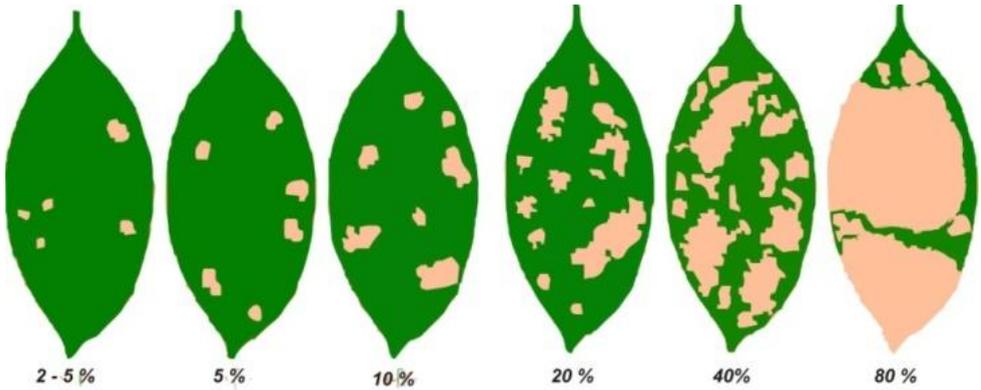


Figura 4. 9 Escala de Capucho y col. para la evaluación del avance de la enfermedad por roya

Fuente: Capucho, Zambolim, Duarte y Vázquez (2011)

SAGARPA (2013) por su parte propone evaluar el avance de la enfermedad tanto a nivel de la hoja como de la planta y presenta para cada caso una escala de clases (Figura 4. 10).

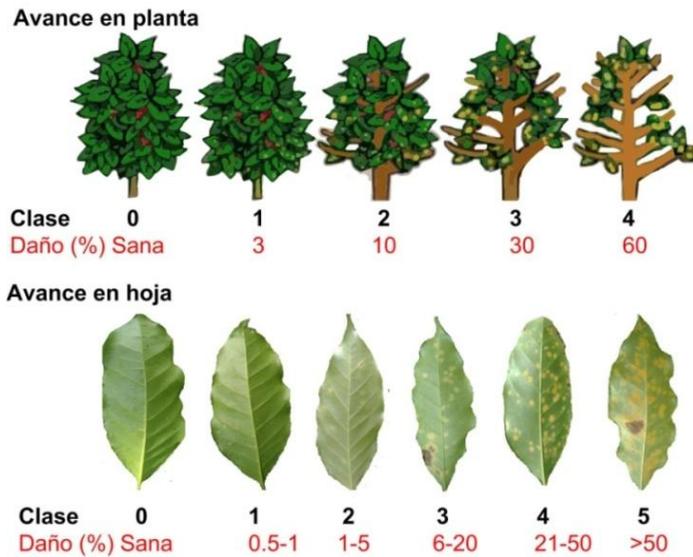


Figura 4. 10 Escalas propuesta por SAGARPA para evaluación de daño por roya

Fuente: Gonzáles y Ramirez (2013)

En la actualidad y sobre todo en las zonas rurales, los técnicos y productores de café realizan el análisis y diagnóstico visual de esta enfermedad; no siendo posible cuantificar objetivamente el grado de daño causado por la enfermedad ni detectar sus estadios temprano. Por esta razón se planteo como objetivo el desarrollar un sistema capaz de evaluar la infección de la roya en estadios temprano mediante la técnica de imágenes hiperespectrales.

#### **4.5. Materiales y metodología**

##### **4.5.1. Material biológico**

La muestra se compone de 140 hojas de café (*var. typica*), esta variedad *typica* fue elegida por ocupar el 70 % del total del área de cafetales, con diversos grados de afectación por roya, recolectadas en una plantación de café en el distrito de Limabamba, coordenadas U.T.M. 218 449.67 y 9 277 022.70, provincia de Rodríguez de Mendoza, región Amazonas, Perú, Figura 4.11.

El clima en esta localidad es cálido y húmedo, con lluvias intensas entre los meses de noviembre a marzo y temperaturas que oscilan entre 12 y 30 °C; estas condiciones climáticas sumadas al hecho que en el Perú el 90 % del café crece bajo sombra y el 70% del área de cafetales está cubierta

por café de variedad *Typica* (Escalante, 2014) favorecen la propagación del hongo tal como se explico en punto 4.3 ítem d.

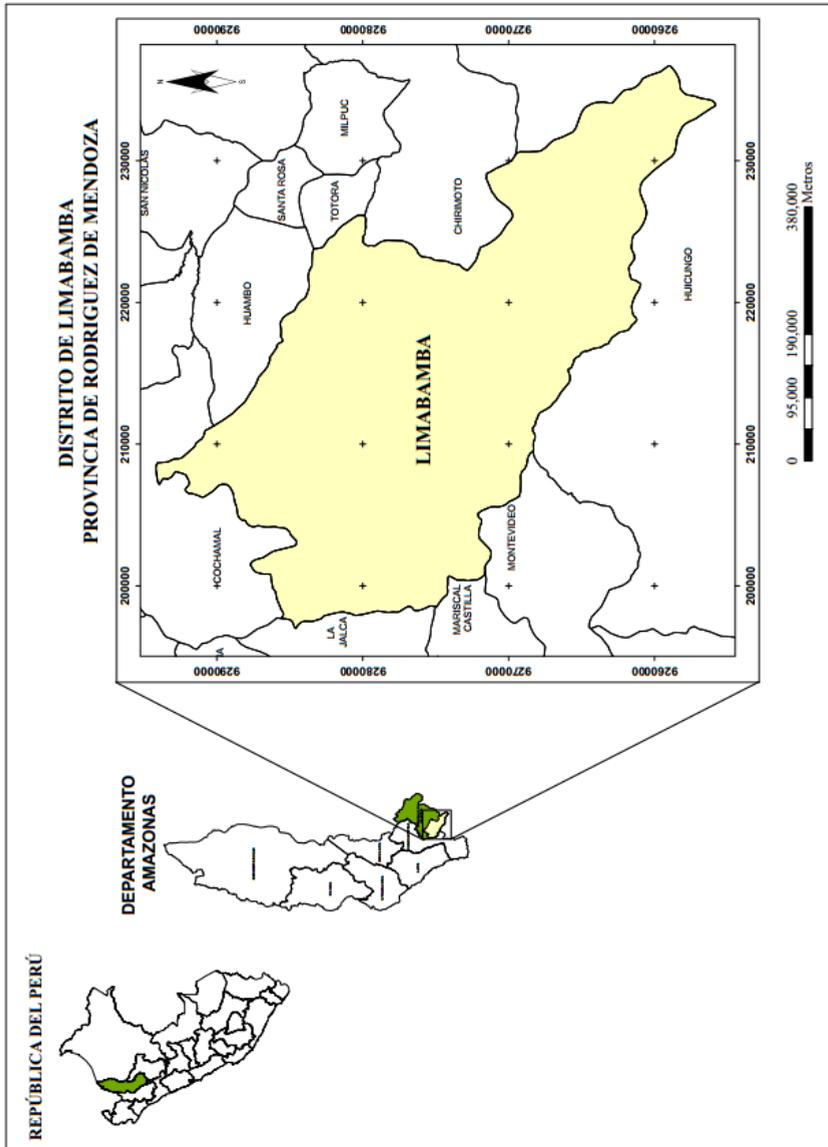


Figura 4. 11 Ubicación geográfica del distrito de Limabamba

#### **4.5.2. Sistema de imágenes hiperespectrales.**

El sistema usado para la adquisición de imágenes hiperespectrales se describe en detalle en el Capítulo II; en resumen este consta de una cámara hiperespectral, sistema de iluminación, plataforma de desplazamiento de muestra, software de adquisición y corrección de imágenes y software de pre-procesamiento y análisis de imágenes; en cuanto a los detalles del software para el análisis de este caso de estudio, desarrollado en esta tesis, se encuentra en el Capítulo III.

#### **4.5.3. Metodología**

La metodología utilizada en este estudio, Figura 4. 12 se basó en los pasos para el análisis de imágenes hiperespectrales mostrados en la Figura 1.4 y elaborados a partir de las propuestas de Liu, Sun y Zen (2013); Liu y col. (2013) y Sun, (2010).

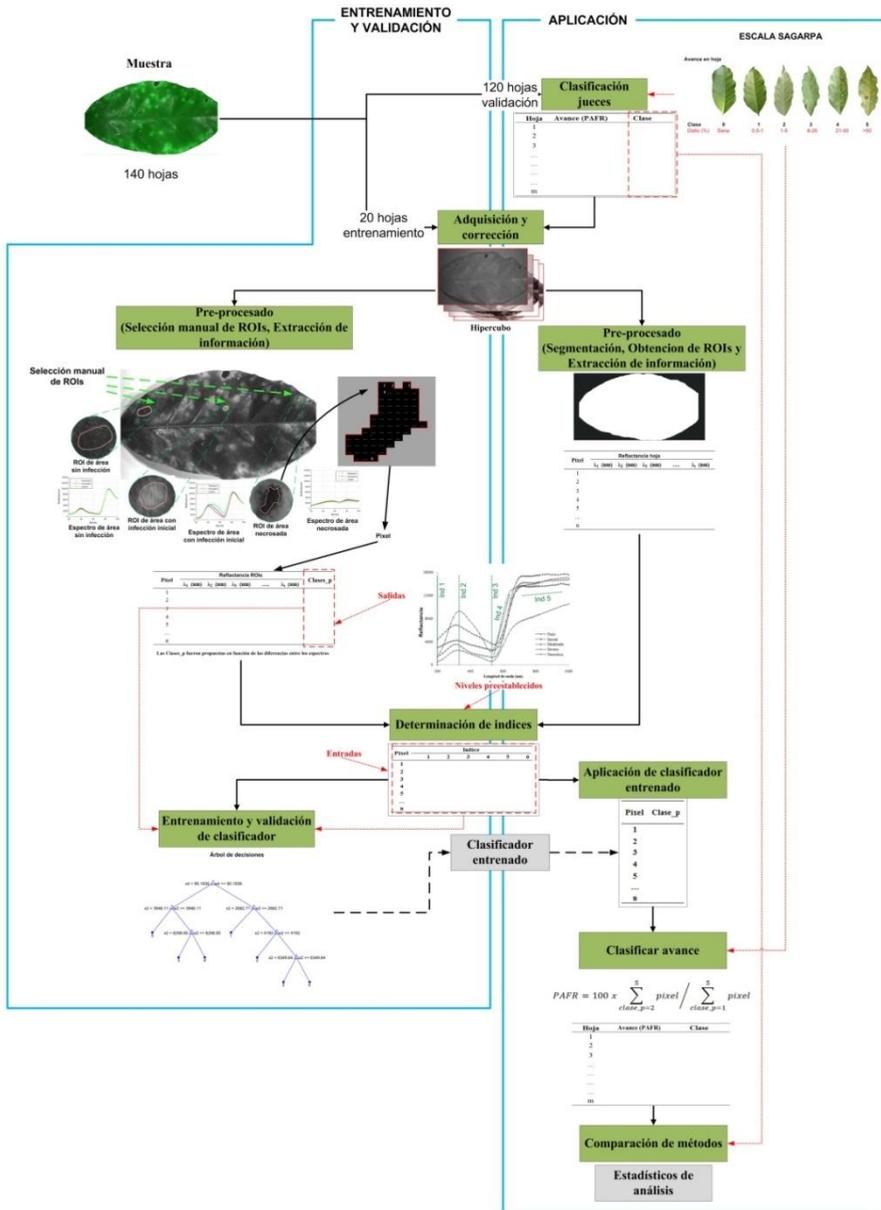


Figura 4. 12 Metodología para el desarrollo de sistema de detección temprana de roya

En las siguientes líneas se comenta cada etapa y sus pasos más importantes:

a) **Entrenamiento y validación.**- En esta etapa se extrajo la información espectral, hipercubo, de veinte hojas procedentes de la muestra; algunas de estas hojas se muestran en la Figura 4. 13 se observan algunas hojas usadas en el proceso de entrenamiento.



Figura 4. 13 Fotografías de algunas hojas de café utilizadas en el entrenamiento del sistema

En cada hipercubo se seleccionaron regiones de interés - ROIs (Regions of Interest), mediante las cuales se entrenó un sistemas experto de clasificación basado en árbol de decisiones. Los pasos de esta etapa se describen a continuación

*a.1) Adquisición y corrección.* La adquisición y corrección de las imágenes hiperespectrales para las muestras de entrenamiento del sistema se detallan en el Capítulo II, ítems 2.3 a 2.5.

*a.2) Pre-procesado.* En este paso se seleccionaron ROIs correspondientes a cinco niveles de daño por roya y a partir de estas se calcularon seis

índices espectrales. Los niveles de daño por roya se establecieron mediante juicio de expertos<sup>8</sup> al observar los cambios de color y forma en áreas con daño por roya; así la escala propuesta en esta tesis, Figura 4.14, clasifica el daño hojas de café en cuatro niveles y estos son visualmente apreciables en la Figura 4.14.

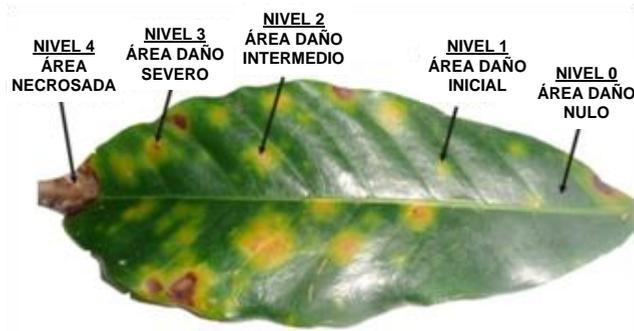


Figura 4. 14 Hoja de café mostrando diferentes áreas y niveles de daño por roya

Tabla 4. 2 Escala con niveles de daño roya en hojas de café

Nivel	Daño	Apariencia visual de la zona
0	Nulo	Color característico de la hoja
1	Inicial	Pequeña mancha clorótica redonda, bordes difusos
2	Intermedio	Mancha clorótica de bordes definida
3	Avanzado	Mancha clorótica con signos iniciales de necrosado, coloración marrón
4	Necrosado	Tejidos de color marrón

La selección ROIs en las hojas de entrenamiento, de los diferentes niveles de daño identificadas por los expertos, se realizó utilizando sus

<sup>8</sup>Técnicos entrenados y especializados en el análisis de infección y daño por roya, proporcionados por el proyecto “Creación del servicio del laboratorio de entomología y fitopatología de la UNTRM-A” en el Instituto de Investigación para el Desarrollo Sustentable de Ceja de Selva en la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas.

imágenes de intensidad a 380 nm y dibujando manualmente máscaras de selección tal como se observa en la Figura 4. 15

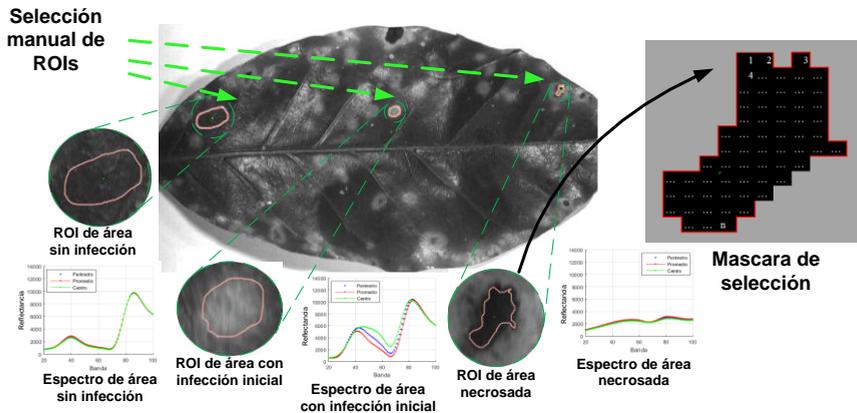


Figura 4. 15 Selección manual de ROIs en hoja de café a diferentes niveles de daño por roya

El conjunto de espectros obtenidos en las distintas ROIs se dispuso en una matriz bidimensional, denominada conjunto de espectros (CE), de dimensiones  $n \times k+1$ ; donde  $n$  es el número filas, correspondiente a los espectros adquiridos, y  $k+1$  las columnas, que contienen la reflectancia en cada bandas del espectro y la clase definida por los evaluadores.

En una evaluación previa de los espectros de los diferentes niveles de daño se observó que la evolución de la enfermedad en la hoja, de mancha clorótica a zona necrosada puede relacionarse con cambios en la firma espectral, tal como se observa en la Figura 4. 15. En este sentido, y a partir de las posiciones de cada pixel se obtuvieron los perfiles

espectrales promedio, correspondientes a los diferentes niveles de daño previamente establecidos, véase Figura 4. 16.

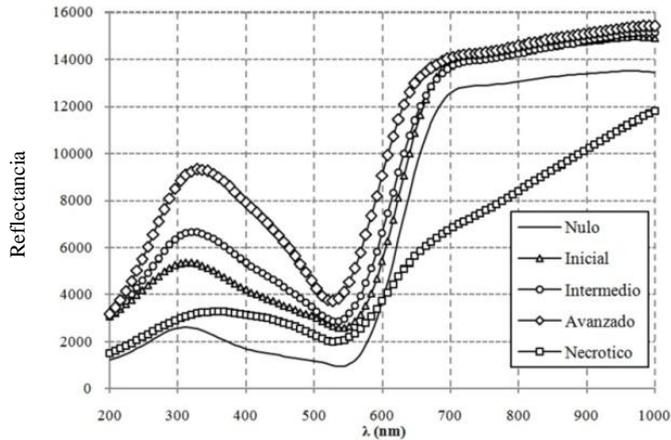


Figura 4. 16 perfiles espectrales promedio en áreas con diferentes niveles de daño por roya

La información o espectro en cada pixel se corrigió espectralmente, mediante el filtro de Savitzky-Golay de 2º orden; de acuerdo a lo explicado en el Capítulo III.

*a.3) Determinación de índices espectrales.* Debido a que cada espectro del  $CE_{na}$  contiene un número elevado de bandas de alta colinealidad se estimo conveniente reemplazar estos por un conjunto de valores o índices espectrales que los representen (mínimos, máximos, ratios, pendientes, entre otros) y se calculen a partir de los antes mencionados espectros.

Este método de reducción de la dimensionalidad, basado en el uso de índices espectrales existentes o la propuesta de nuevos índices, forma parte del análisis de imágenes hiperespectrales (Rud, Shoshany, y Alchanatis, 2013) y ejemplos del uso de índices espectrales se encuentran en investigaciones como la de Yang y col., (2014) o Dumont y col., (2015) quienes probaron diferentes índices para clasificar áreas sanas y enfermas en tomate así como determinar la viabilidad de semillas; logrando tasas de exactitud de 86 a 95 % y 62 % respectivamente.

A partir de la observación de los perfiles espectrales promedio, para los diferentes niveles de daño mostrados en la Figura 4. 16, se propusieron y calcularon seis índices espectrales, véase Tabla 4. 3, a fin de reemplazar el espectro de los píxeles de cada ROI.

Tabla 4. 3 Índices espectrales para el análisis de roya

Índice	Descripción	$\lambda$ (nm)
Ind 1	Valor de intensidad (I)	200
Ind 2	Valor de intensidad máxima ( $I_M$ )	[200 - 400]
Ind 3	Valor de intensidad mínima ( $I_m$ )	[480 - 600]
Ind 4	Pendiente I vs $\lambda$	[552 - 616]
Ind 5	Pendiente I vs $\lambda$	[696 - 912]
Ind 6	Relación Ind 4 / Ind 5	---

*a.4) Entrenamiento y validación de clasificador.* El entrenamiento del clasificador se realizó utilizando el sistema detallado en el Capítulo II;

---

determinando en este paso la combinación de índices espectrales y tamaño de árbol de decisión que minimizo el error de clasificación durante el entrenamiento, obtenido este clasificador se almaceno en formato \*.mat

**b) Aplicación.**- La aplicación del sistema, uso las hojas seleccionadas para este fin, iniciando con la codificación y clasificación visual por expertos; posteriormente se obtuvieron y corrigieron sus imágenes hiperespectrales. Cada hipercubo se pre-proceso, obteniendo la posición de cada pixel en las hojas, extrayendo su informaron espectral y calculando sus índices espectrales. Estos índices se usaron, mediante el sistema entrenado en la etapa anterior, para calcular el PAFR y determinar el avance en la hoja según la escala de SAGARPA. En las siguientes líneas se profundizara cada paso.

*b.1 Clasificación por jueces.* Las hojas fueron clasificadas visualmente de acuerdo al grado de severidad, de daño por roya tomando como base la escala de SAGARPA (Figura 4. 10). La clasificación se realizó por los técnicos entrenados y especializados en el análisis de infección y daño por roya que participaron en el paso a.2 (Figura 4. 17).



Figura 4. 17 Clasificación de hojas con daño por roya mediante inspección visual

*b.2) Adquisición y corrección de imágenes.* Las imágenes de cada una de las hojas de validación (120) fueron adquiridas y corregidas tal como se hizo para las muestras de entrenamiento; véase ítem a.1 del presente capítulo.

*b.3) Pre-procesado.* En este paso se crearon ROIs que a diferencia de la creación manual realizada en el paso a.1, usó la técnica de segmentación por umbralizado; comentada en el Capítulo II.

Obtenidas las ROIs se determinaron los perfiles espectrales de los pixel que las conformaba.

*b.4) Determinación de índices.* A partir de los perfiles espectrales, obtenidos en el paso anterior, se calcularon sus índices espectrales, de acuerdo a la Tabla 4. 3. Estos índices caracterizaron cada uno de los pixeles de las hojas de café como paso previo a su clasificación por el sistema entrenado.

*b.5) Aplicación de clasificador entrenado.* La clasificación de los pixeles de cada hoja se realizo usando tanto el clasificador, creado en el paso a.4 del entrenamiento, como sus índices espectrales. Esta clasificación se realizo recorriendo los pixeles de las ROI y trasladando los resultados, previamente traducidos en escala de colores de acuerdo a la severidad propuesta en la Figura 4.14, a una imagen clasificada (Figura 4. 18).

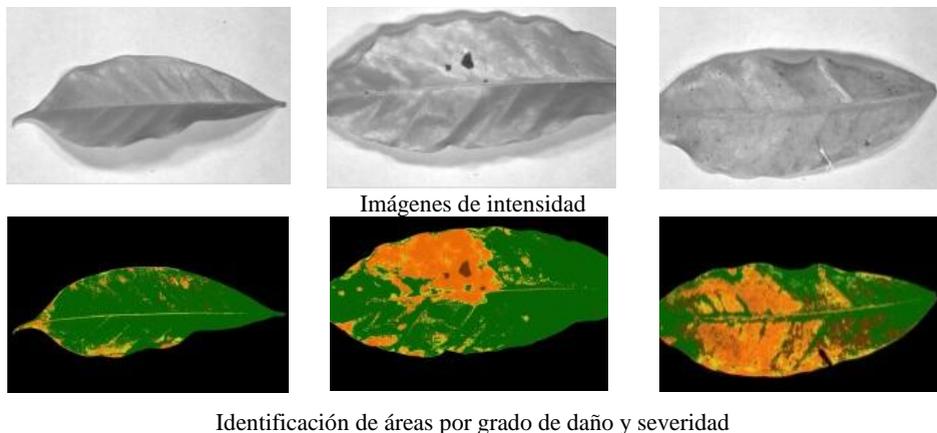


Figura 4. 18 Imágenes de intensidad e imágenes clasificadas por severidad de daño por roya

*b.6) Clasificación de avance.* El avance del daño por roya, expresado como porcentaje de área afectada por roya (PAFR), se calculo mediante la Ecuación 4.2 la cual totaliza la cantidad de pixeles por cada nivel de daño.

$$PAFR = 100 \cdot \left( \frac{\sum_{\text{clase}=2}^5 (\text{pixel}_{\text{clase}})}{\sum_{\text{clase}=1}^5 (\text{pixel}_{\text{clase}})} \right) \dots \dots \text{Ecuación 4.2}$$

Donde:

PAFR = Porcentaje de área afectada por roya

Pixel<sub>clase</sub> = Píxeles por clase

Finalmente cada hoja fue clasificada, según la escala SAGARPA y el PAFR.

*b.7) Evaluación del sistema.* El sistema desarrollado en esta investigación fue comparado con los resultados por la clasificación por jueces; en este sentido se determino: a) Si existen diferencias estadísticamente significativas, b) El método de clasificación que resulta en mayores valores de clase y c) El método de clasificación de mayor sensibilidad.

## **4.6. Resultados y discusión**

### **4.6.1 Entrenamiento y validación**

El total de espectros que conformo el CE fue 23 643; los cuales, después de la eliminación de anómalos, se obtuvo el CE<sub>na</sub> compuesto por 8 299 espectros, Tabla 4. 4.

Tabla 4. 4 Distribución de espectros utilizados para el cálculo de los índices espectrales

Nivel	Espectros	
	CE	CE <sub>na</sub>
0	4375	2338
1	2876	1002
2	4837	1199
3	3391	1008
4	8164	2752
Total	23643	8299

La eliminación de espectros anómalos se propone como un paso a considerar en el pre-procesamiento de ROIs; este paso evita errores por la inclusión de píxeles no correspondientes a clases en selección. En este sentido estudios como los de Barbedo, Tibola y Fernandes (2015); Cheng y col. (2015) que realizan segmentación mediante umbralizado, el de Cho y col. (2013), seleccionando ROIs cuadradas o los de Coelho, Soto, Torres, Sbarbaro, y Pezoa (2013); Dai, Cheng, Sun, y Zeng (2014) que utilizaron selección manual de ROIs no reportan correcciones como la propuesta en esta investigación.

Utilizando los espectros del CE<sub>na</sub> y las combinaciones de los índices, propuestos en Tabla 4.3, se crearon, entrenaron y validaron árboles de decisión de número de ramas variable. La validación, de tipo cruzado, determinó el error de cada combinación y tamaño de árbol. Posteriormente se seleccionaron y graficaron las combinaciones de

menor error de validación cruzada, véase Figura 4. 19, seleccionándose la combinación de índices 3, 5 y 6 para el desarrollo del modelo a aplicar en este estudio.

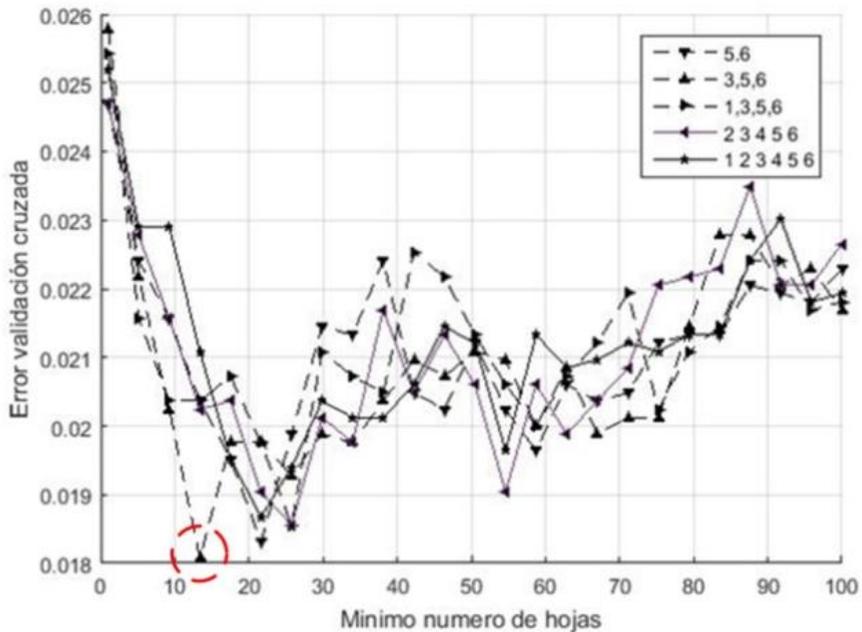


Figura 4. 19 Errores de validación en arboles de decisión para la clasificación del nivel de daño por roya

La combinación de índices obtenida y el número mínimo de hojas obtenidas en el paso anterior fueron usadas para crear el árbol de decisiones a utilizar en los procesos de clasificación del avance del daño por roya y cuya estructura se muestra en la Figura 4. 20.

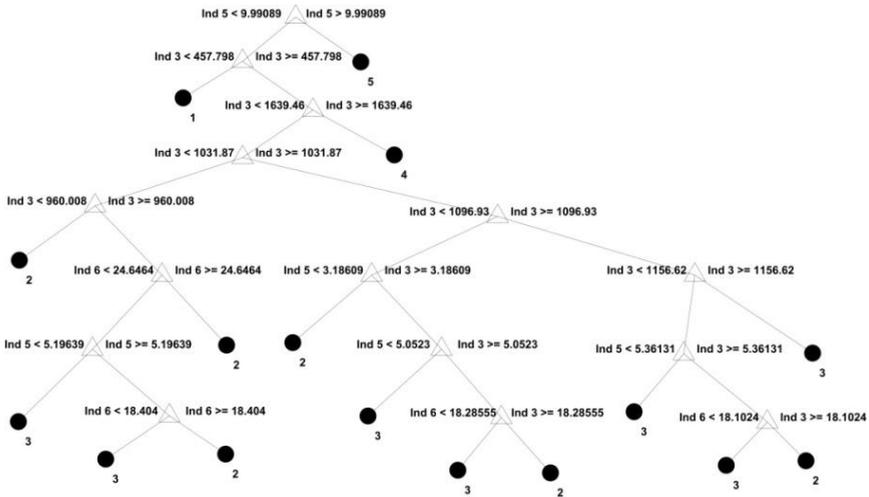


Figura 4. 20 Esquema del árbol de decisiones

A fin de caracterizar el error de este árbol de decisiones se calculo el error por validación cruzada el cual alcanzo el valor de 0.0063; concordante con el coeficiente de exactitud global (99.37 %) calculado a partir de la matriz de confusión, Figura 4. 21.

CLASE REAL	1	2338 100.0 %	0 0 %	0 0 %	0 0 %	0 0 %	TVP TFN
	2	0 0 %	942 97.6 %	60 2.4 %	0 0 %	0 0 %	
	3	0 0 %	37 2.3 %	1162 97.7 %	0 0 %	0 0 %	
	4	0 0 %	0 0 %	0 0 %	1008 100.0 %	0 0 %	
	5	0 0 %	0 0 %	0 0 %	0 0 %	2751 100.0 %	
	CLASE PREDICHA	1	2	3	4	5	

Figura 4. 21 Matriz de confusión del árbol de decisiones

---

El coeficiente de exactitud obtenido para la determinación de áreas infectadas por roya en hojas de café, en los diferentes niveles propuestos por esta investigación, es comparable con los coeficientes de correlación o exactitud por la aplicación de esta técnica en la determinación de infección o contaminación microbiana. Así los coeficientes obtenidos en trabajo como el de Coelho, Soto, Torres, Sbarbaro, y Pezoa (2013), 85 % para la clasificación de infección en almejas; Lu y Ariana (2013), 82 – 93%; Barbedo, Tibola, y Fernandes (2015), 91% para la infección por mosca de la fruta o Ravikanth, Singh, Jayas, y White (2015), 60.9 – 90.1% para la infección por Fusarium, entre otros, se han mostrado por debajo de los obtenidos en este trabajo para la determinación de la enfermedad de la roya del café en sus estadios tempranos.

#### 4.6.2 Aplicación

Los resultados obtenidos usando el clasificador entrenado se compararon con los obtenidos mediante la clasificación por jueces; para este efecto se utilizaron 120 hojas de café con diferentes niveles de daño por roya. Obteniéndose diferentes grados de afectación, según el método usado, Figura 4. 22.

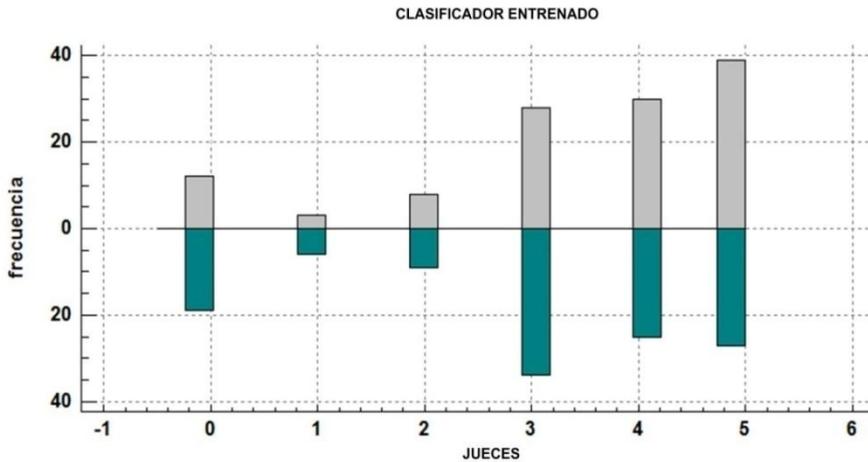


Figura 4. 22 Frecuencia de clases obtenidas mediante clasificador entrenado y jueces

Como se aprecia existen diferencias en los resultados de ambos métodos; por cuanto se realizó el análisis estadístico no paramétrico a fin de determinar si dichas diferencias son significativas. Se aplicó la prueba de Kolmogorov-Smirnov determinando que existen diferencias estadísticamente significativas, véase Tabla 4. 5.

Tabla 4. 5 Prueba de Kolmogorov-Smirnov para la clasificación

Estadísticos		Clasificador	Jueces
N		120	120
Parámetros normales <sup>a</sup>	Media	3.49	3.01
	Desviación típica	1.55	1.68
Diferencias más extremas	Absoluta	0.21	0.22
	Positiva	0.17	0.12
	Negativa	-0.21	-0.22
Z de Kolmogorov-Smirnov		2.32	2.35
p- Sig. asintótica (bilateral) <sup>b</sup>		0.00	0.00

<sup>a</sup> La distribución de contraste es la Normal.

<sup>b</sup> Los datos de ambas variables son normales ( $p=0.000<0.05$ )

Posteriormente se determinó, mediante la prueba de los rangos con signos de Wilcoxon, el método que resulta en mayores valores de clase

Tabla 4. 6.

Tabla 4. 6 Prueba de los rangos con signo de Wilcoxon

<b>Jueces – Clasificador</b>	<b>N</b>	<b>Rango promedio</b>	<b>Suma de rangos</b>
Rangos negativos	52(a)	27.07	1 407.50
Rangos positivos	1(b)	23.50	23.50
Empates	67(c)		
<b>Total</b>	<b>120</b>		

- a. Jueces < Sistema
- b. Jueces > Sistema
- c. Jueces = Sistema

De los estadísticos de contraste, Tabla 4. 7, se corrobora que existe diferencia estadísticamente significativa entre jueces y sistema ( $p=0.000 < 0.05$  - Prueba Wilcoxon); además se determinó que las valoraciones del clasificador son significativamente superiores a la de los jueces.

Tabla 4. 7 Estadísticos de contraste para la relación Clasificador - Jueces

<b>Estadístico</b>	<b>Jueces - Clasificador</b>
Z	-6.687(a)
Sig. asintót. (bilateral)	0.000(b)

- a. Basado en los rangos positivos.
- b. Prueba de los rangos con signo de Wilcoxon

Finalmente; se usaron las muestras comprendidas en las clases 0 y 0.5, 12 unidades, véase Tabla 4.8.

Tabla 4. 8 Estadísticos de la muestra PAFR

<b>N</b>	<b>Media</b>	<b>Desviación típ.</b>	<b>Error típ.</b>
12	0.1167	0.103	0.030

A partir de estos datos se determino que existe diferencia significativa entre el PFAR obtenido con el clasificador y el mínimo obtenido con la escala SAGARPA, aplicando la prueba t-Student  $p=0.000<0.05$  (Tabla 4. 9) a un nivel de confianza del 95%.

Tabla 4. 9 Prueba para una muestra

<b>t</b>	<b>gl</b>	<b>Sig. (bilateral)</b>	<b>Diferencia de medias</b>	<b>95% Intervalo de confianza para la diferencia</b>	
				<b>Inferior</b>	<b>Superior</b>
-12.894	11	0.000	-0.38333	-0.4488	-0.3179

De esta manera existe evidencia estadística suficiente para afirmar que el PFAR es inferior al mínimo propuesto los por la escala SAGARPA y se propone replantear la escala a usar de acuerdo a esta metodología.

Como se aprecia de otras investigaciones los trabajos revisados y que compararon métodos de análisis en imágenes hiperespectrales como el de Abdel y col. (2014), que evaluó los métodos PLSR y SPLSR en la predicción del rendimiento de cultivos bajo distintas fuentes de irrigación, logrando coeficientes de correlación en los rangos de [0.64 a 0.54] y [0.94 – 0.92] respectivamente o el de Fernandes y col. (2013) quien obtuvo coeficientes de correlación de 93.5 y 93.1 para redes

neuronales y PLSR en la predicción de la densidad de madera o de Dumont y col. (2015) que comparo los rangos de longitud de onda UV-VIS y SWIR en la evaluación de la viabilidad de semillas y obtuvo el máximo coeficiente de correlación (93 %) en el rango SWIR.

Sin embargo; todos estos estudios utilizaron la comparación de los resultados de sus métodos con un análisis patrón, lo cual para el caso de la Roya no es posible debido a que los análisis reportados por Avelino y Rivas (2013); Gonzáles y Ramirez (2013); Guerra Burgos y Welchez Arita (2013); Rivillas-Osorio, Serna-Giraldo, Cristancho-Ardila, y Gaitán-Bustamante (2011); Santacre, Reyes, y Oseguera (1983) para la roya del café son visuales y en tal sentido los resultados de este trabajo se proponen como base de nuevas técnicas de análisis para estadios tempranos de esta enfermedad.

#### **4.7. Conclusiones**

- La aplicación del sistema desarrollado el análisis de la infección temprana por roya en hojas de café, muestra diferencias estadísticamente significativas con respecto al análisis por jueces. Asimismo; del análisis estadístico, se observa que la clasificación de infecciones por roya mediante el clasificador entrenado es superior

---

en una unidad a las clases obtenidas en evaluación por jueces. Este hecho se debe a mayor sensibilidad del método; determinado por la sensibilidad del sistema en detectar PAFR a valores menores a 0.5 % y mismos que la escala SAGARPA no toma en cuenta para las clasificaciones.

- Por tanto; en base a su mayor sensibilidad el sistema desarrollado, basado en clasificador por árbol de decisiones, ofrece mayor fiabilidad debido a su carácter de análisis objetivo – cuantitativo y la capacidad demostrada de determinar y cuantificar menores valores de PAFR.
- Los resultados obtenidos en este trabajo son especialmente importantes para el desarrollo de sistemas automatizados capaces de evaluar el estado fitosanitario de plantaciones de café y brinda un camino a seguir para la aplicación de esta tecnología al análisis de otros tipos de problemas de plagas y enfermedades en cultivos de café o similares.

### **Referencias bibliográficas**

- Abdel, E., Mutanga, O., Odindi, J., Adam, E., Odindo, A., y Ismail, R. (2014). A comparison of partial least squares (PLS) and sparse {PLS}

- 
- regressions for predicting yield of Swiss chard grown under different irrigation water sources using hyperspectral data. *Computers and Electronics in Agriculture*, 106, 11 – 19
- Alzate, N. (2015). Importancia del gen sh3 y su relación con la resistencia a la enfermedad roya del café *hemileia vastatrix* bajo la modalidad de compilación bibliográfica.
  - Arvy, M., Gallouin, F., Ubillos, M. y Montalbán, J. (2007). *Espicias, aromatizantes y condimentos*. Vol. 77. Mundi-Prensa.
  - Avelino, J. y Rivas, G. (2013). La roya anaranjada del café.
  - Barbedo, J., Tibola, C. y Fernandes, J. (2015). Detecting *Fusarium* head blight in wheat kernels using hyperspectral imaging. *Biosystems Engineering*, 131, 65 – 76.
  - Capucho, A., Zambolim, L., Duarte, H. y Vaz, G. (2011). Development and validation of a standard area diagram set to estimate severity of leaf rust in *Coffea arabica* and *C. canephora*. *Plant Pathology*, 60(6), 1144–1150.
  - Cheng, J., Sun, D., Pu, H., Chen, X., Liu, Y., Zhang, H. y Li, J. (2015). Integration of classifiers analysis and hyperspectral imaging for rapid discrimination of fresh from cold-stored and frozen-thawed fish fillets. *Journal of Food Engineering*, 161, 33 – 39.

- 
- Cho, B., Kim, M., Baek, I., Kim, D., Lee, W., Kim, J., ... Kim, Y. (2013). Detection of cuticle defects on cherry tomatoes using hyperspectral fluorescence imagery. *Postharvest Biology and Technology*, 76, 40 – 49.
  - Coelho, P., Soto, M., Torres, S., Sbarbaro, D., y Pezoa, J. (2013). Hyperspectral transmittance imaging of the shell-free cooked clam *Mulinia edulis* for parasite detection. *Journal of Food Engineering*, 117(3), 408 – 416.
  - Cristancho, M., Rozo, Y., Escobar, C., Rivillas, C. y Gaitan, A. (2013). Razas de roya: Epidemias de 2008 a 2011.
  - Dai, Q., Cheng, J.-H., Sun, D.-W., y Zeng, X.-A. (2014). Potential of hyperspectral imaging for non-invasive determination of mechanical properties of prawn (*Metapenaeus ensis*). *Journal of Food Engineering*, 136, 64 – 72.
  - Dumont, J., Hirvonen, T., Heikkinen, V., Mistretta, M., Granlund, L., Himanen, K., ... Keinänen, M. (2015). Thermal and hyperspectral imaging for Norway spruce (*Picea abies*) seeds screening. *Computers and Electronics in Agriculture*, 116, 118 – 124.

- Escalante, N. (2014). Cambios en la demanda mundial de alimentos y la exportación de café orgánico (2005-2012) (Tesis de maestría). Universidad de San Martín de Porres, Lima-Perú.
- Farah, A. y Dos Santos, T. (2015). The Coffee Plant and Beans: An Introduction. In *Coffee in Health and Disease Prevention. Brazil: Elsevier*.
- Fernandes, A., Lousada, J., Morais, J., Xavier, J., Pereira, J. y Melo-Pinto, P. (2013). Comparison between neural networks and partial least squares for intra-growth ring wood density measurement with hyperspectral imaging. *Computers and Electronics in Agriculture*, 94, 71 – 81.
- Gonzáles, R., y Ramirez, M. (2013). Manual técnico para el manejo preventivo de la roya del cafeto. Dirección General de Sanidad Vegetal.
- Gotteland, M. y De Pablo, V. (2007). Algunas verdades sobre el café. *Revista Chilena de Nutrición*, 34(2), 105–115.
- Guerra, J. y Welchez, J. (2013). Evaluación de la efectividad de cuatro fungicidas biológicos en el control del hongo de la roya de café *Hemileia vastatrix*.

- 
- Huamán, I. (2014). Oportunidades de Negocio en el Mercado Chino: Café Orgánico.
  - Jackson, D., Skillman, J. y Vandermeer, J. (2012). Indirect biological control of the coffee leaf rust, *Hemileia vastatrix*, by the entomogenous fungus *Lecanicillium lecanii* in a complex coffee agroecosystem. *Biological Control*, 61(1), 89–97.
  - Lagos, S. (2014). Efecto de la condición química del suelo y de la fertilización sobre la incidencia, severidad y resistencia fisiológica de plantas de café a la roya (*Hemileia vastatrix*).
  - Liu, D., Sun, D. y Zen, X. (2013). Recent advances in wavelength selection techniques for hyperspectral image processing in the food industry. *Food and Bioprocess Technology*, 7, 307–323.
  - Lu, R., y Ariana, D. (2013). Detection of fruit fly infestation in pickling cucumbers using a hyperspectral reflectance/transmittance imaging system. *Postharvest Biology and Technology*, 81, 44 – 50.
  - Márquez-Dávila, K., Arévalo, L. y Gonzáles, R. (2014). Efectos del abonamiento nitrogenado sobre la roya amarilla (*hemileia vastatrix* berck et. br.) en dos variedades de *Coffea arabica* L. *Folia Amazónica*, 23(1), 57–66.

- 
- OEEE. (2013). Situación del mercado del Café en grano (Informe especial No. 001-2013) (p. 10). Lima: MINAGRI.
  - OEEE. (2015). sistemas de información. Lima-Perú: MINAGRI.
  - Panhuysen, S. y Pierrot, J. (2014). Barómetro de Café 2014.
  - Ravikanth, L., Singh, C., Jayas, D., y White, N. (2015). Classification of contaminants from wheat using near-infrared hyperspectral imaging. *Biosystems Engineering*, 135, 73 – 86.
  - Rayner, R. (1961). Germination and penetration studies on coffee rust (*Hemileia vastatrix* B. y Br.). *Annals of Applied Biology*, 49(3), 497–505.
  - Rivillas-Osorio, C., Serna-Giraldo, C., Cristancho-Ardila, M. y Gaitán-Bustamante, A. (2011). La roya del cafeto en Colombia, impacto, manejo y costos de control. *Avances Tecnicos Cenicafe*. Chinchiná, Colombia: Cenicafé.
  - Rojo Jiménez, E., Pérez-Urria Carril, E., Rojo Jiménez, E., y Pérez-Urria Carril, E. (2014). Café I (*G. Coffea*). *REDUCA Biología*, 7(2), 113–132.
  - Rud, R., Shoshany, M. y Alchanatis, V. (2013). Spatial–spectral processing strategies for detection of salinity effects in cauliflower, aubergine and kohlrabi. *Biosystems Engineering*, 114(4), 384 – 396.

- 
- SAGARPA. (2013). Ficha técnica de la roya del cafeto *Hemileia vastatrix* Berkeley y Broome (p. 28). México: Secretaria General de Agricultura Desarrollo Rural Pesca y Alimentación.
  - Santacre, R., Reyes, E. y Oseguera, S. (1983). Estudio del desarrollo de la roya del cafeto *Hemileia vastatrix* berk et br y su relacion con factores biologicos y climaticos en condiciones de campos en dos zonas cafetaleras de honduras. In VI Simposio Latinoamericano sobre caficultura (pp. 199–215). Panamá: IICA Biblioteca Venezuela.
  - Santos, P., Carrión, Ó., Tirabanti, J. y Arévalo, F. (2014). Impacto económico de *Hemileia vastatrix* en 11 caseríos del ámbito de influencia del proyecto Café, distrito de Alonso de Alvarado, provincia de Lamas, región San Martín.
  - Sun, D. (2010). *Hiperspectral Imaging for Food Quality Analisis And Control*. San Diego - USA.: Elsevier.
  - Yang, C., Kim, M., Millner, P., Chao, K., Cho, B., Mo, C., ... Chan, D. E. (2014). Development of multispectral imaging algorithm for detection of frass on mature red tomatoes. *Postharvest Biology and Technology*, 93, 1 – 8.

---

**5. Aplicación de la técnica de imágenes hiperespectrales en la detección de adulteración de queso fresco con harina de maíz**

---

## **5.1. Introducción**

La seguridad alimentaria es reconocida como una parte integral de la seguridad alimentaria y como se indica en la declaración de la Cumbre Mundial de la Alimentación de 1996: "Existe seguridad alimentaria cuando todas las personas tienen en todo momento acceso físico, social y económico a suficientes alimentos inocuos y nutritivos para satisfacer sus necesidades alimenticias y sus preferencias alimentarias para llevar una vida activa y sana" (Unnevehr, 2015). En este sentido la seguridad se ha constituido en un tema de preocupación para la población mundial; basando esta en los efectos de los alimentos, su forma de producirlos y manipularlos (Fu y col., 2014).

Dicha seguridad alimentaria puede ser afectada, en cualquier etapa de la producción y/o manipulación de los alimentos, con acciones como la adulteración de alimentos. Esta es una acción intencional para degradar la calidad, antes, durante o después del proceso de producción; bien sea por una mezcla, sustitución o la eliminación de algunos componentes del alimento (Calderón-Rangel, Rodríguez y Martínez, 2013).

En la industria láctea la adulteración con harinas es una problemática común desde la leche hasta los productos terminados. En la leche fresca

---

se adiciona harina para restablecer algunos parámetros fisicoquímicos y enmascarar la adición de agua (Calderón-Rangel y col., 2013); asimismo se ha reportado su adición en leche en polvo (Karthek, Smith, Muthu y Manavalan, 2011) y como adulterante en quesos tipo fresco y mantecoso (Boucher, Guégan y Riveros, 2004). Esto pone en evidencia la necesidad de nuevos métodos y procedimientos de detección para asegurar la calidad de los productos lácteos. En el caso del queso fresco, según el Codex Alimentario, se autoriza el uso de almidones y harinas siempre y cuando se utilicen dosis funcionalmente necesarias (FAO, 2001b); así la concentración máxima resultante de almidón o gelatinizante presente en los quesos frescos es de 5 g/kg (FAO, 2000).

En la determinación de la presencia de almidón en quesos frescos se recomienda el método oficial AOAC 940.24, en cuanto que para leches existen otras metodologías (FAO, 2001a), así como en alimentos en general (COVENIN, 1998; Grandy, Erich y Porter, 2000; Halhoul y Kleinberg, 1972; Jermyn, 1975; Somani, Khanade y Sinha, 1987), basada en el uso de reacciones químicas y medidas físicas (principalmente espectrofotométricas) que requieren reactivos y personal altamente calificado.

---

En la detección de adulterantes se vienen utilizando tecnologías como la cromatografía de gases para quesos (Kim y col., 2014; Majcher, Lawroski, y Jelén, 2010); y la técnica PCR (polymerase chain reaction) para identificar el uso de leche de bufalo en queso Mozzarella (Feligini y col., 2005).

Las técnicas ópticas, no destructivas, tales como la espectroscopia NIR y el análisis de imágenes hiperespectrales (HSI) están siendo utilizadas actualmente en el control de la calidad alimentaria (Andueza, Agabriel, Constant, Lucas y Martin, 2013; Sun, 2010). La espectroscopia NIR ha demostrado un gran potencial en el análisis de atributos sensoriales en quesos Cheddar (Downey y col., 2005), en la determinación de composición en quesos Emmental (Karoui, y otros, 2006), en el análisis de quesos madurados elaborados con distintos tipos de leche (González-Martín y col., 2007), en la determinación composicional de quesos madurados (Čurda y Kukačková, 2004) y en la composición de ácidos grasos en quesos frescos (Lucas, Andueza, Ferlay y Martin, 2008). El HSI, en comparación con la espectroscopia NIR, proporciona información del alimento tanto espacial como espectral de manera simultánea.

En la industria láctea, la aplicación de imágenes hiperespectrales está dirigida a la monitorización de procesos, el análisis composicional, la predicción de concentraciones de componentes, y en general al control de la calidad y seguridad alimentaria (Gowen, Burger, O'Callagan y O'Donnell, 2009). Una revisión actualizada de los análisis analíticos acoplados con herramientas quimiométricas, como las imágenes, para determinar la adulteración de productos lácteos la realiza Kamal y Karoui (2015).

En este Capítulo se desarrollo un método para evaluar la adulteración de queso fresco con harina de maíz, utilizando imágenes hiperespectrales, de acuerdo a los siguientes pasos: a) adulteración de muestras de queso fresco, durante el proceso de producción, con harina de maíz; b) cuantificación de la presencia de almidón de maíz en muestras; c) adquisición de imágenes hiperespectrales; d) construcción de modelos PLSR; e) aplicación de modelos de predicción a imágenes hiperespectrales de nuevas muestras.

### 5.1.1. Materiales y metodología

### 5.1.2. Material biológico

Para la producción de las muestras de queso queso aculterado se utilizó leche fresca procedente de vacas Yérsey de la estación ganadera experimental “Chachapoyas” de la Universidad Nacional Toribio Rodríguez de Mendoza de Chachapoyas (UNTRM), cuyas características y composición se muestran en la Tabla 5. 1; como material adulterante se utilizó harina de maíz adquirida en un mercado local y caracterizada mediante espectrofotometría NIR, siendo el contenido de almidón de 78.06 % (p/p).

Tabla 5. 1 Caracterización de la leche utilizada

<b>Parámetro</b>	<b>Valor</b>
Grasa (%)	3.855
Extracto seco magro (%)	9.71
Proteína (%)	3.65
Lactosa (%)	5.09
Densidad (g/cm <sup>3</sup> )	1.0312
Minerales (%)	0.66
pH leche	6.625
Acidez (Grados Dornic)	16
Punto de congelación (°C)	-0.516

### 5.1.3. Procedimiento experimental

La metodología propiamente dicha fue dividida en las etapas mostradas en la Figura 5. 1.

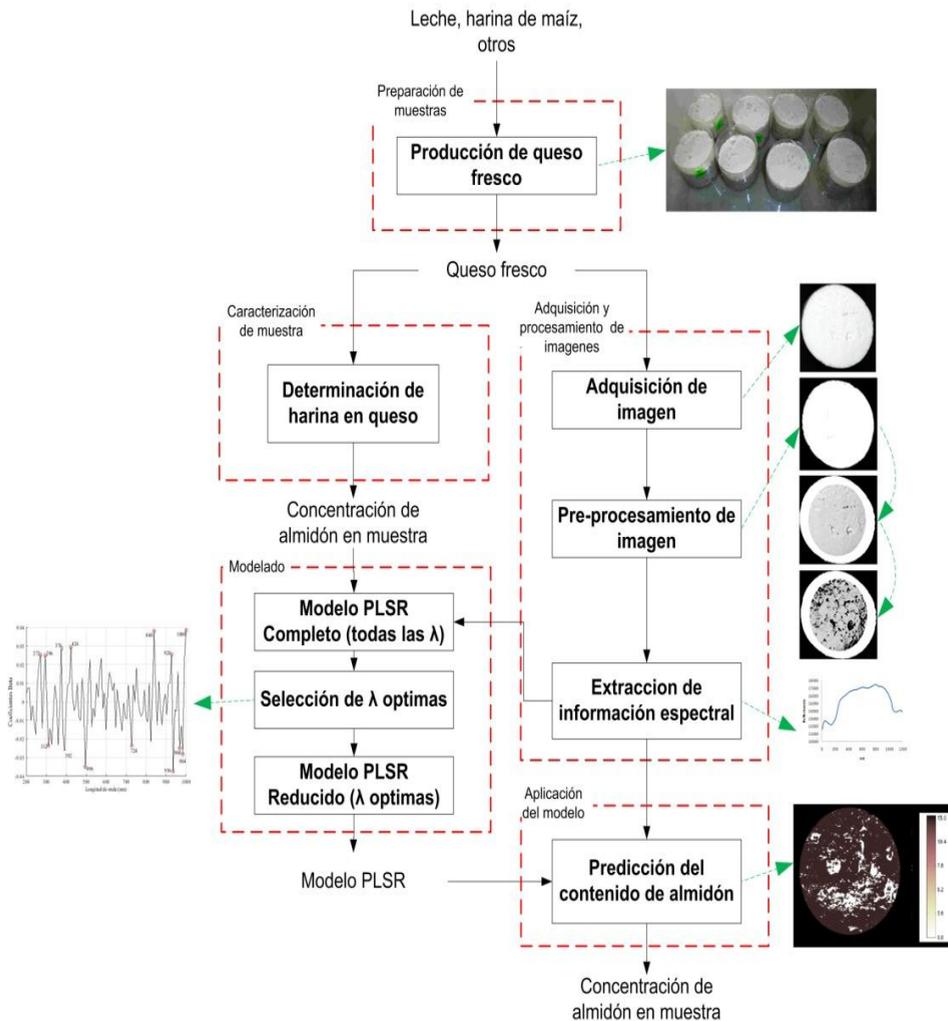


Figura 5. 1 Descripción esquemática del procedimiento experimental

En los siguientes apartados se brindan mayores detalles de cada una de dicha etapas:

a) **Preparación de muestras.** El diagrama de flujo para la producción de queso fresco adulterado con harina de maíz obtenido para los efectos de esta investigación, se muestra en la Figura 5. 2.

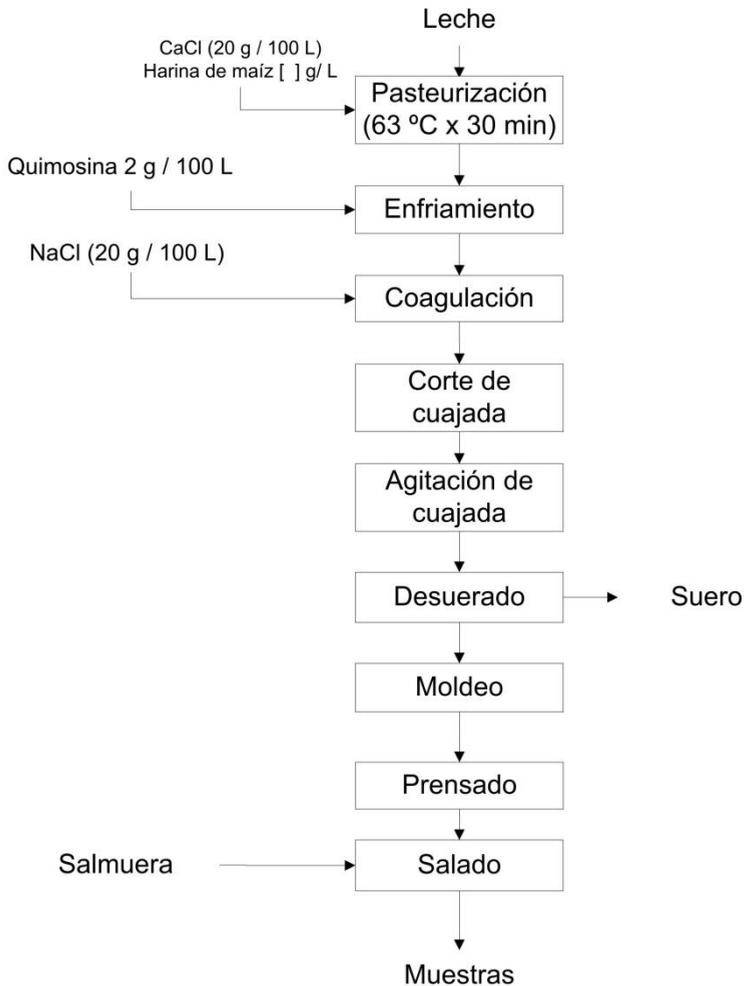


Figura 5. 2 diagrama de flujo para la preparación de muestras

Fueron preparadas once muestras de queso fresco, diez conteniendo harina de maíz en diferentes concentraciones y una muestra de control.

**b) Caracterización de muestras.** Para la determinación cuantitativa de almidón en las muestras de queso fresco se usó el método de la Antrona, previamente reportado por Grandy y col. (2000); Halhoul y Kleinberg

---

(1972); Somani y col. (1987); el proceso se desarrollo como se detalla  
continuacion:

*Construccion de curva patrón*

- Preparar soluciones de glucosa anhidra disuelta en agua a concentraciones de 1, 2, 5, 7 y 10 mg de almidón / agua ml.
- Tomar 10 ml de las soluciones y añadir antrona.
- Espere 10 minutos mientras que un color verde-azul
- Leer la absorbancia a 620 nm de longitud de onda en un espectrofotómetro.
- Construir curva de calibración usando el contenido de absorbancia y almidón de cada solución.

*Determinacion del contenido de almidon*

- Pesar 2 g de la muestra de queso fresco.
- Triturar y disolver en 10 ml de agua destilada.
- Espere 2 horas.
- Añadir antrona, esperar 10 minutos y leer la absorbancia.
- Calcular el contenido de almidón usando la curva de calibración.

c) **Adquisición y procesamiento de imágenes.** Esta etapa consistió de los siguientes pasos:

*c.1 Adquisición de imágenes hiperespectrales.* Para obtener las imágenes de las muestras estas fueron seccionadas, en rodajas de 5 cm de diámetro y 1 cm de alto (Figura 5. 3). Se utilizaron 4 rodajas por muestra para la toma de imágenes; fijando los siguientes parámetros: velocidad de desplazamiento de 0.5 cm/s, distancia entre la lente y la superficie de la plataforma, 28.3 cm y apertura de diafragma, 6.4 mm, 100 longitudes de onda en el rango de 200 a1200 nm.

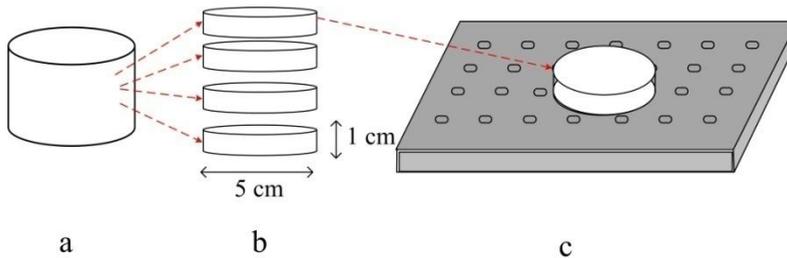


Figura 5. 3 Acondicionamiento de las muestras de queso. a) forma cilíndrica inicial de cada muestra b) obtención de rebanadas c) posicionamiento de las muestras en la plataforma móvil para la toma de imágenes.

Se tomaron 24 imágenes para la etapa de calibración (1 imagen por rodaja ó 4 imágenes por muestra incluyendo las rodajas de la muestra control; y 20 imágenes para la etapa de validación del modelo (1 imagen por rodaja).

*c.2 Pre-procesamiento de la imagen.* El pre-procesamiento comprendió corrección espacial, espectral y eliminación de píxeles anómalos, usando los métodos comentados en los Capítulos II y III.

*c.3 Extracción de información espectral.* Este paso inicio con la segmentación usando el método basado en umbralizado (tresholding) a 480 nm, fijando esta longitud d onda por el alto contraste entre la muestra y el fondo (Figura 5. 4 b); el método en detalle se explica en el ítem 2.1 del Capítulo 2.

Obtenida la imagen segmentada se determino el radio máximo de la muestra ( $R$ ) mediante la función *Regionprops* de Matlab. Posteriormente se selecciono automáticamente una ROI, creando una máscara de selección de forma circular cuyo centro coincidió con el centro geométrico de la muestra y el radio de esta igual a  $0.75 R$  (Figura 5. 4 b).

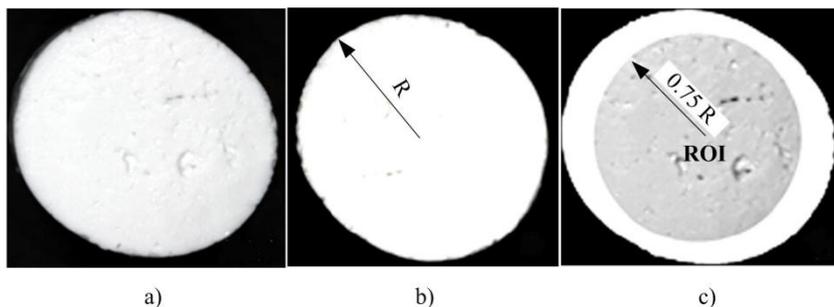


Figura 5. 4 a) imagen RGB b) imagen de intensidad a 480 nm c) imagen de ROI circular

A partir de ROI seleccionada se extrajo la información espectral de de cada uno de los pixeles que la conforman, Figura 5. 5.

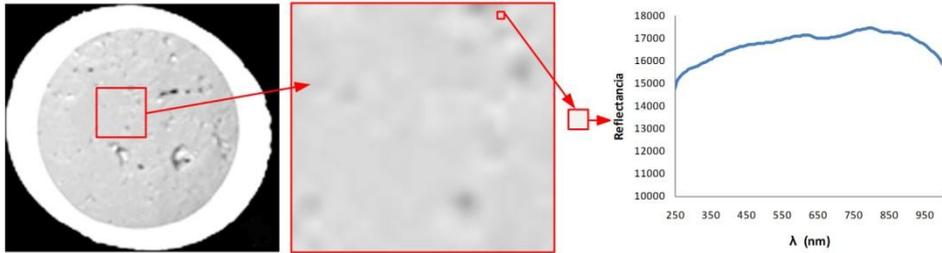


Figura 5. 5 Extracción de información espectral en la ROI

Los perfiles anómalos fueron eliminados usando el método descrito en el Capítulo III. El proceso se ilustra en la Figura 5. 6; en la imagen a se aprecia una fotografía en formato RGB, la cual muestra aéreas de mayor y menor luminosidad (debidas a presencia de humedad o concavidades). Estas aéreas fueron removidas obteniéndose la imagen b, en la cual los pixeles removidos se representados como zonas oscuras.

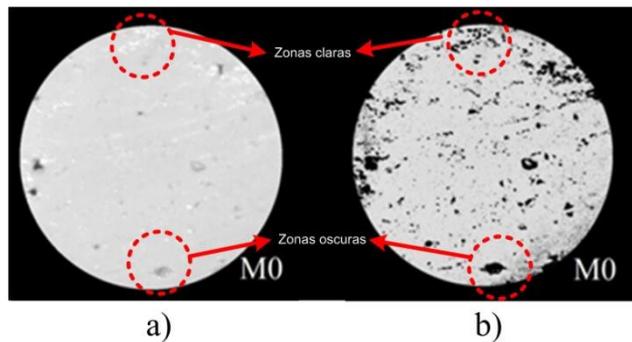


Figura 5. 6 a) Imagen RGB muestra M0 b) Imagen intensidad pixeles anómalos removidos

---

A partir de la imagen b de la Figura 5. 6 se determino el perfil espectral promedio de cada muestra.

**d) Modelado.** Como fue explicado en el Capítulo I, tabla 1.6, existen diferentes métodos para modelar las relaciones entre los perfiles espectrales y los parámetros en estudio. Uno de los métodos más usados es el método de mínimos cuadrados parciales (PLSR) el cual ha sido aplicado en los trabajos de Barbin, Sun y Su (2013); Liu, Sun y Zen (2013) y ElMasry y col. (2007), entre otros.

Los detalles de la aplicación de este método se brindan en el Capítulo III, en tanto que en los siguientes párrafos se comentaran brevemente los principales pasos para la labor de análisis de las imágenes abarcadas en este Capítulo.

*d.1 Modelo PLSR completo.* Los datos obtenidos de las 24 muestras a usar en el desarrollo del modelo, perfil espectral y concentraciones de almidón, se ajustaron mediante el modelo PLSR (Ecuación 5.1).

$$Y = B.\lambda + e \dots \text{Ec. 5.1}$$

Donde:

Y = Matriz de concentraciones de almidón [24 x 1]

B = Matriz de coeficientes de regresión

$\lambda$  = Matriz de datos espectrales [24 x 100]

$e$  = Error del modelo.

Como se aprecia de la Figura 5. 7 y la Ecuación 5.1 el modelo completo utiliza la totalidad de las longitudes de onda; esto genera una elevada sensibilidad y poca robustez en el modelo. En tal sentido se procedió a reducir el número de longitudes de onda para el cálculo de la concentración de almidón con el modelo PLSR.

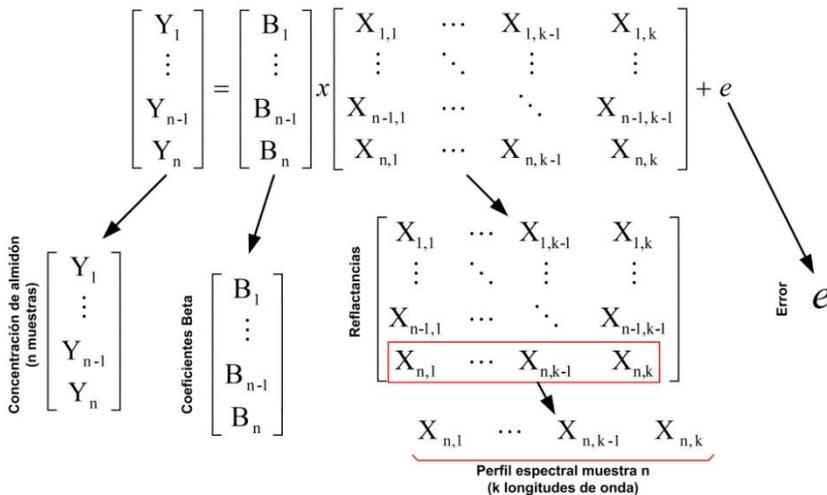


Figura 5. 7 Estructura del modelo PLSR

*d.2 Selección de las longitudes de onda óptimas.* La reducción del número de longitudes de onda a usarse en el modelo PLSR se realizó utilizando el método explicado en el Capítulo III.

*d.3 Modelo PLSR reducido.* Se realizó el mismo procedimiento de la etapa *d.1*, con la modificación de la matriz  $X$  ( $X_{[24 \times 14]}$ ), obteniendo así un nuevo modelo PLSR o PLSR reducido.

e) **Aplicación de Modelo PLSR.** El modelo PLSR reducido se aplicó a tres muestras adicionales de queso fresco, adulterado con diferentes concentraciones de almidón. Estas muestras, al igual que las muestras para el modelado, se dividieron en cuatro discos a fin de obtener de estas 12 imágenes hiperespectrales.

A cada imagen se aplicaron los pasos descritos para la etapa c y posteriormente el modelo PLSR reducido, obteniéndose tanto la composición como la imagen quimiométrica.

## **5.2. Resultados y discusión**

En las siguientes líneas se presenta y discute los principales resultados obtenidos en la presente investigación:

### **5.2.1. Caracterización de muestras**

En la

---

Tabla 5. 2 se muestran algunos parámetros obtenidos en la caracterización de las muestras de calibración y aplicación.

Tabla 5. 2 Diseño experimental y parámetros obtenidos en el análisis de las muestras

Etapa	M	IH	H/L (mg /ml )	A/L (mg /ml )	RND (g/ml)	A/Q (mg /g )	P. A. (%)	H (%)	A.B.S (mg /g )
Calibración	M1	4	2.5	2.0	0.23	2.7	75.1	56.6	5.9
	M2	4	7.5	5.9	0.28	6.0	77.9	54.6	13.2
	M3	4	12.5	9.8	0.27	7.9	82.6	54.6	17.4
	M4	4	17.5	13.7	0.27	9.9	84.8	54.7	21.8
	M5	4	22.5	17.6	0.29	12.7	83.8	53.5	27.3
Aplicación	V1	4	5.0	3.9	0.26	3.2	83.4	52.1	6.6
	V2	4	8.0	6.2	0.27	6.2	78.8	57.1	14.4
	V3	4	10.0	7.8	0.27	8.1	78.3	52.8	17.2
	V4	4	16.0	12.5	0.28	7.9	86.3	53.9	17.3
	V5	4	20.0	15.6	0.27	11.6	84.0	54.0	25.3

*IH:* Numero de Imágenes Hiperespectrales tomadas a la muestra.

*H/L:* Cantidad de harina de maíz agregada en miligramos por mililitros de leche durante el proceso de elaboración.

*A/L:* Cantidad de almidón agregada en miligramos por mililitros de leche durante el proceso de elaboración, calculada a partir de H/L y el contenido de almidón en la harina (78.06%).

*RND:* Rendimiento quesero en gramos de queso fresco por mililitro de leche.

*A/Q:* Concentración de almidón.

*P. A.:* Porcentaje de pérdida de almidón tras el proceso de elaboración del queso.

*A.B.S.:* Concentración de almidón en base seca.

Las muestras de calibración y validación se adulteraron por adición de harina de maíz; esta adición se realizó en los rangos de 2.5 a 22.5 y de 5.0 a 20.0 mg harina de maíz /ml de leche respectivamente, equivalente a concentraciones de 1.95 a 17.56 mg de almidón / ml de leche. El rendimiento promedio de las muestras en función a la leche fue de 0.26 g/ml, mientras que la muestra control tuvo un rendimiento de 0.25 g/ml.

La harina de maíz se adicionó, al proceso de producción de las muestras de queso, durante la etapa de pasteurización con el fin de reducir las pérdidas del almidón en el suero, debido esto a la menor movilización del

---

almidón en su forma gelatinizada (Larsen, 2009). Sin embargo; se registraron pérdidas de este componente entre 75 al 87%, en función al contenido teórico de almidón. Una de las razones para esta pérdida es la naturaleza del almidón presente en la harina, que al ser nativo tiene un poder gelificante menor en comparación al almidón modificado o el tipo waxy (Vaclavik y Christian, 2014). Otro razón importante fue el alto contenido graso de la leche utilizada en esta investigación (5.8%); lo cual en quesos alterados, de imitación o análogos, de acuerdo a lo reportado por Agudelo, Sepúlveda, y Restrepo (2015); Bachmann (2001); Kartheek y col. (2011); Larsen (2009); Mounsey y Riordan (2008), reduce la capacidad del almidón de formar una red para retener las caseínas durante la coagulación.

### **5.2.2. Adquisición y procesamiento de imágenes**

En la Figura 5. 8 se observa una imagen en formato (\*.RGB) de cada tratamiento antes de la toma de imágenes hiperespectrales.

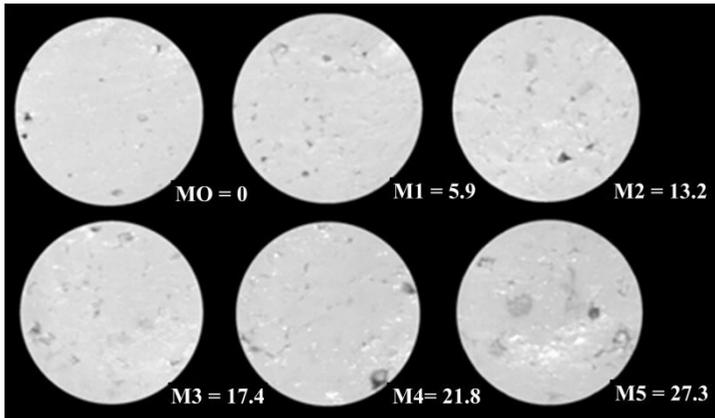


Figura 5. 8 Muestras de queso previas a la adquisición de imagen hiperespectral; cada muestra presenta el contenido de almidón en mg/g

Como se observa las muestras presentan áreas de mayor o menor reflectancia; debidas a la presencia de humedad superficial, protuberancias y cavidades lo cual afecta al análisis del perfil espectral. Por tanto; como refiere Sun (2010), un requisito para el análisis de imágenes es optimizar la calidad de la imagen o mejorar estas digitalmente.

Los perfiles espectrales contenidos en las ROIs de los tratamientos para modelado y validación se promediaron y graficaron en la Figura 5. 9; así se observa que la muestra control (M0) tiene los valores más altos de reflectancia en el rango [200 - 1000] nm, y que conforme la contenido de almidón aumenta los valores de intensidad del espectro disminuyen.

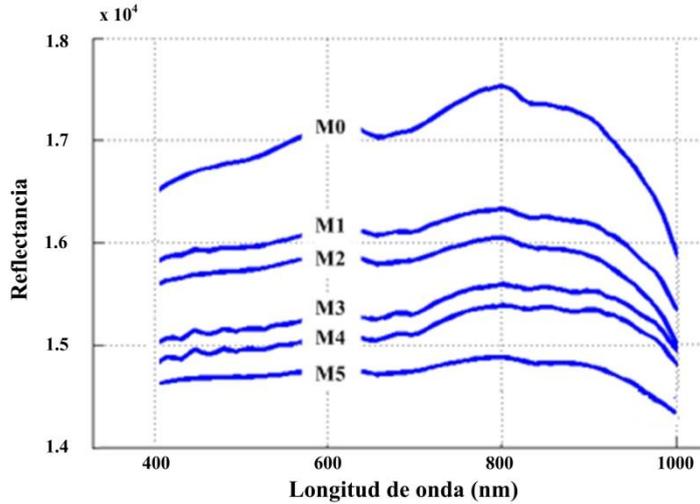


Figura 5. 9 Intensidad vs longitud de onda para los tratamientos

### 5.2.3. Modelado

Se realizó el modelado de la relación entre las longitudes de onda y los contenidos de almidón mediante PLSR tomando la totalidad de las longitudes de onda; logrando los coeficientes de correlación ( $r^2$ ) de validación de 0.93, véase Figura 5. 10 b.

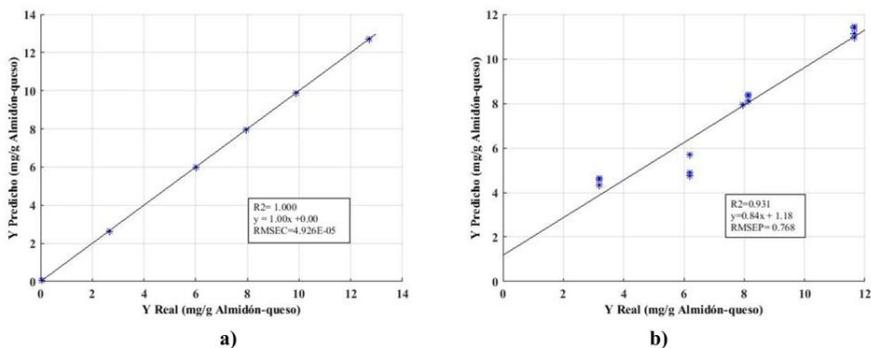


Figura 5. 10 Curvas del modelo PLSR completo en a) calibración b) validación

Aplicando el método PCA se determino muestran que el valor de la suma mínima predecible de los residuos al cuadrado (PRESS) se hace mínima

al implementar un modelo PLSR con nueve variables latentes o longitudes de onda, Figura 5. 11.

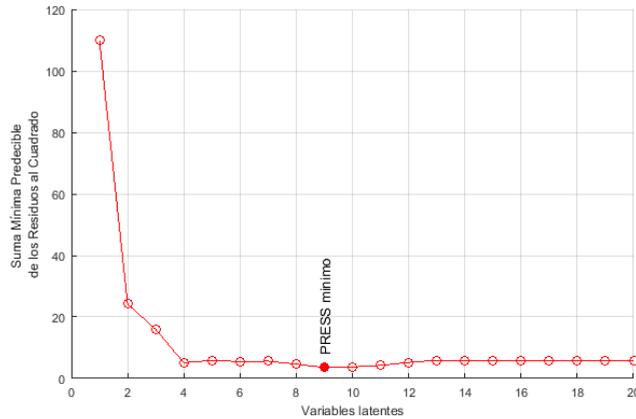


Figura 5. 11 Valor PRESS para las variables latentes del modelo PLSR

Estas nueva longitudes de onda se seleccionaron de acuerdo a los coeficientes Beta como se aprecia en la Figura 5. 12.

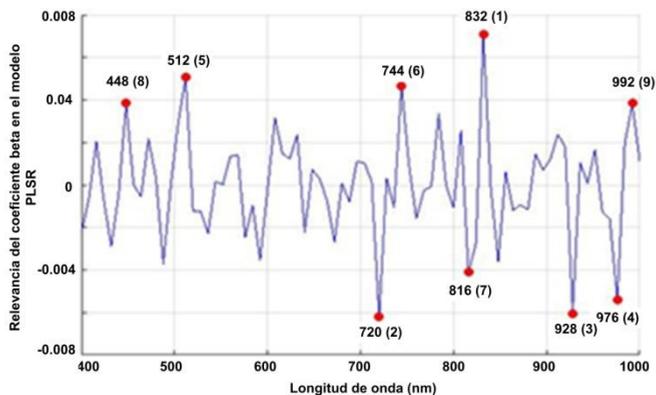


Figura 5. 12 Beta coeficientes del modelo PLSR

De acuerdo a los coeficientes Beta, los rangos de 448 a 512 nm y 744 a 992 nm, están íntimamente ligados al contenido de almidón; esto

confirma lo reportado en el trabajo de Gorretta y col. (2006) quien determino que el rango de 378 a 780 nm está íntimamente relacionado con el contenido de almidón en alimentos así como lo realizado por Katayama, Komaki y Tamiya (1996) que usando transmitancias a 765, 874, 910, 948 y 997 nm modelaron el contenido de almidón en camote. Estas investigaciones explican la razón de la disminución de la reflectancia a mayor contenido de almidón, Figura 5. 9 y el amplio rango de longitudes de onda seleccionadas por el análisis PLSR, Figura 5. 12.

Utilizando estas nueve longitudes de onda se genero un nuevo modelo PLSR, denominado modelo reducido, cuya se muestra en la Ecuación 5.2.

$$Y_{\text{pred}} = \beta_1\lambda_{448} + \beta_2\lambda_{512} + \dots + \beta_{14}\lambda_{992} + e \dots \text{Ec. 5.2}$$

Dónde:  $\beta_1 = -0.04667$ ;  $\beta_2 = 0.05487$ ;  $\beta_3 = -0.16825$ ;  $\beta_4 = 0.20416$ ;  $\beta_5 = -0.07989$ ;  $\beta_6 = 0.02602$ ;  $\beta_7 = -0.00606$ ;  $\beta_8 = -0.01896$ ;  $\beta_9 = 0.03292$ ;  $e = 40.37595$

Este nuevo modelo presento un error cuadrático medio de la validación cruzada de 0.551 (RMSECV). A partir de estos coeficientes se realizó la predicción del contenido de almidón en cinco muestras donde se obtuvo

un error cuadrático medio de predicción de 0.872 (RMSEP) y coeficiente de correlación ( $r^2$ ) de 0.917, véase Figura 5. 13.

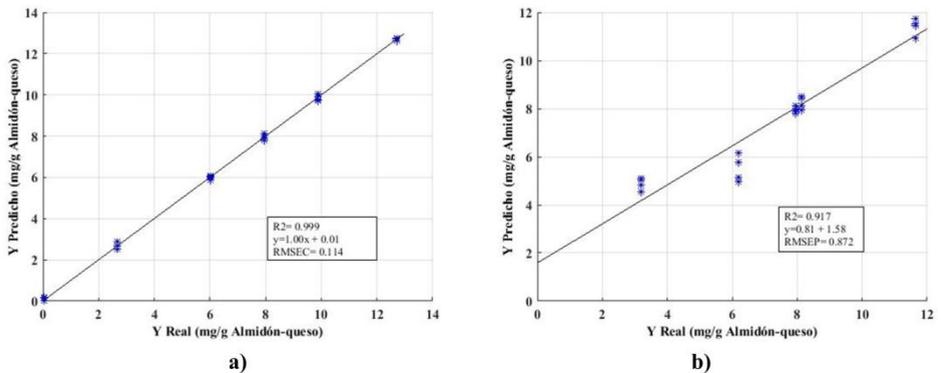


Figura 5. 13 Curvas del modelo PLSR reducido en a) calibración b) validación

#### 5.2.4. Aplicación del modelo

El modelo desarrollado en el paso anterior se implementó, obteniéndose imágenes de quimiométricas de acuerdo a la presencia de almidón en las muestras, las cuales pueden apreciarse en la Figura 5. 14. Donde las imágenes de menor contenido de almidón presentan una coloración de blanca, siendo la imagen de queso sin almidón (0 mg /g) de color completamente blanco y a medida que el contenido aumenta la coloración con tendencia al color marrón (13 mg /g).

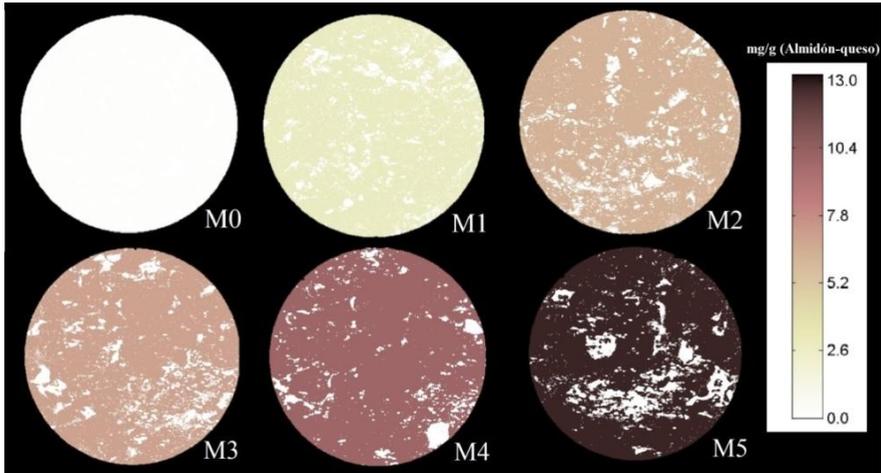


Figura 5. 14 Imágenes de intensidad relacionadas con el contenido de almidón

### 5.3. Conclusiones

- El contenido de almidón en las muestras de queso muestran relación con su perfil espectral promedio.
- Se determinó que en el rango de 400 a 100 nm es posible modelar la relación entre el contenido de almidón y el perfil espectral mediante regresión de mínimos cuadrados parciales, usando nueve variables latentes o longitudes de onda.
- Es posible predecir el contenido de almidón en las muestras con una precisión del 99.16 % para un modelo PLSR completo o del 91.68 % para un modelo PLSR reducido.

- Las longitudes de onda que muestran mayor influencia en el modelo PLSR para determinar el contenido de almidón en las muestra de queso se concentran en el rango de 700 a 1000 nm.
- Se ha mostrado que la aplicación de la técnica de imágenes hiperespectrales al análisis de la adulteración por harina de maíz en queso fresco permite detectar la presencia de dicho adulterante; en base a la relación entre la reflectancia y el contenido de almidón en muestras de queso fresco.

---

## Referencias bibliográficas

- Agudelo, J., Sepúlveda, J. y Restrepo, D. (2015). Efecto de la adición de dos tipos de almidones en las propiedades texturales de queso análogo, 68, 7545–7555.
- Andueza, D., Agabriel, C., Constant, I., Lucas, A., y Martin, B. (2013). Using visible or near infrared spectroscopy (NIRS) on cheese to authenticate cow feeding regimes. *Food Chemistry*, 141(1), 209–214.
- Bachmann, H. (2001). Cheese analogues: a review, 11, 505–515.
- Barbin, D., Sun, D., y Su, C. (2013). NIR hyperspectral imaging as non-destructive evaluation tool for the recognition of fresh and frozen - thawed porcine longissimus dorsi muscles. *Innovative Food Science and Emerging Technologies*, 18, 226–236.
- Boucher, F., Guégan, M., y Riveros, H. (2004). Queserías rurales en Cajamarca. Perú: Iica.
- Calderón-Rangel, A., Rodríguez, V., y Martínez, N. (2013). Determinación de adulterantes en leches crudas acopiadas en procesadoras de quesos en Montería (Córdoba), 17, 202–206.
- COVENIN. (1998). Determinación del contenido total de almidón. In *Carne y productos cárnicos*. Caracas-Venezuela: Fondo Norma.

- 
- Čurda, L., y Kukačková, O. (2004). NIR spectroscopy: a useful tool for rapid monitoring of processed cheeses manufacture. *Journal of Food Engineering*, 61(4), 557–560.
  - Downey, G., Sheehan, E., Delahunty, C., O’Callagan, D., Guinee, T., y Howard, V. (2005). Prediction of maturity and sensory attributes of Cheddar cheese using near-infrared spectroscopy, 15, 701–709.
  - ElMasry, G., Wang, N., ElSayed, A., y Ngadi, M. (2007). Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry, 81, 98–107.
  - FAO. (2000). Métodos de muestreo y análisis para productos lácteos. Wellington: Comisión del codex alimentarius.
  - FAO. (2001a). CODEX STAN 221-2001. Norma colectiva para el queso no madurado, Incluido El Queso Fresco.
  - FAO. (2001b). Norma del CODEX para el queso no madurado, incluido el queso fresco. CODEX STAN.
  - Feligini, M., Bonizzi, I., Cubric Curik, V., Parma, P., Greppi, G. F., y Enne, G. (2005). Detection of adulteration in Italian mozzarella cheese using mitochondrial DNA templates as biomarkers. *Food Technology and Biotechnology*, 43(1), 91–95.

- 
- Fu, X., Kim, M. S., Chao, K., Qin, J., Lim, J., Lee, H., ... Ying, Y. (2014). Detection of melamine in milk powders based on NIR hyperspectral imaging and spectral similarity analyses. *Journal of Food Engineering*, 124, 97–104.
  - González-Martín, I., Hernández-Hierro, J., Morón-Sancho, R., Salvador-Esteban, J., Vivar-Quintana, A., y Revilla, I. (2007). Determination of the percentage of milk (cow's, ewe's and goat's) in cheeses with different ripening times using near infrared spectroscopy technology and a remote reflectance fibre-optic probe. *Analytica Chimica Acta*, 604(2), 191–196.
  - Gorretta, N., Roger, J., Aubert, M., Bellon-Maurel, V., Campan, F., y Roumet, P. (2006). Determining vitreousness of durum wheat kernels using near infrared hyperspectral imaging. *Journal of Near Infrared Spectroscopy*, 14(1), 231.
  - Gowen, A., Burger, J., O'Callagan, D., y O'Donell, C. (2009). Potential applications of hyperspectral imaging for quality control in dairy foods, 65–81.
  - Grandy, A., Erich, M., y Porter, G. (2000). Suitability of the anthrone–sulfuric acid reagent for determining water soluble

- 
- carbohydrates in soil water extracts. *Soil Biology and Biochemistry*, 32(5), 725–727.
- Halhoul, M., y Kleinberg, I. (1972). Differential determination of glucose and fructose, and glucose-and fructose-yielding substances with anthrone. *Analytical Biochemistry*, 50(2), 337–343.
  - Jermyn, M. A. (1975). Increasing the sensitivity of the anthrone method for carbohydrate. *Analytical Biochemistry*, 68(1), 332–335.
  - Kamal, M., y Karoui, R. (2015). Analytical methods coupled with chemometric tools for determining the authenticity and detecting the adulteration of dairy products: A review. *Trends in Food Science y Technology*, 46(1), 27–48.
  - Kartheek, M., Smith, A., Muthu, A. y Manavalan, R. (2011). Determination of Adulterants in Food: A Review, 3, 629–636.
  - Katayama, K., Komaki, K. y Tamiya, S. (1996). Prediction of Starch, Moisture, and Sugar in Sweetpotato by Near Infrared Transmittance. *HortScience*, 31(6), 1003–1006.
  - Kim, N., Lee, J., Han, K., Kim, J., Cho, S. y Kim, J. (2014). Discrimination of commercial cheeses from fatty acid profiles and phytosterol contents obtained by GC and PCA. *Food Chemistry*, 143, 40–47.

- 
- Larsen, K. (2009). Effects of starch addition on low fat rennet curd properties and their partitioning between curd and whey.
  - Liu, D., Sun, D. y Zen, X. (2013). Recent advances in wavelength selection techniques for hyperspectral image processing in the food industry. *Food and Bioprocess Technology*, 7, 307–323.
  - Lucas, A., Andueza, D., Ferlay, A. y Martin, B. (2008). Prediction of fatty acid composition of fresh and freeze-dried cheeses by visible–near- infrared reflectance spectroscopy, 18, 595–604.
  - Majcher, M., Lawroski, P. y Jelén, H. (2010). Comparison of original and adulterated oscypek cheese based on volatile and sensory profiles, 9, 265–275.
  - Mounsey, J. y Riordan, E. (2008). Characteristics of imitation cheese containing native or modified rice starches, 22, 1160–1169.
  - Somani, B., Khanade, J. y Sinha, R. (1987). A modified anthrone-sulfuric acid method for the determination of fructose in the presence of certain proteins. *Analytical Biochemistry*, 167(2), 327–330.
  - Sun, D. (2010). *Hyperspectral imaging for food quality analysis and control*. Elsevier.
  - Unnevehr, L. (2015). Food safety in developing countries: Moving beyond exports. *Global Food Security*, 4, 24–29.

- Vaclavik, V. y Christian, E. (2014). *Essentials of Food Science*. New York, NY: Springer New York.
- Xin, J., Wang, Y., Liu, T., Lin, K., Chang, L. y Xia, C. (2012). Biosynthesis of Corn Starch Palmitate by Lipase Novozym 435. *International Journal of Molecular Sciences*, 13(6), 7226–7236.

---

---

**6. Aplicaciones de la técnica de imágenes hiperespectrales a la  
detección de la calidad de carne de res**

---

---

## 6.1. Introducción

La calidad de la carne, por su importante aporte a la dieta de proteínas, vitaminas y minerales y su rápido deterioro por agentes físicos y biológicos, debe ser rigurosamente controlada a fin de determinar su aptitud como alimento fresco o almacenado (Elmasry, Barbin, Sun y Allen, 2012; McAfee y col., 2010). En este control de calidad uno de los atributos sensoriales de mayor influencia, por estar asociado a la palatabilidad, es el marmoleado (Faucitano, Huff, Teuscher, Gariépy y Wegner, 2005; Li, Shan, Peng y Gao, 2011).

En la evaluación del marmoleado se determinan la presencia y distribución de la grasa en la masa muscular de la carne y se relacionan con la calidad sensorial (Xiong, Sun, Zeng y Xie, 2014). Esta evaluación, según el estudio de Lozano y Méndez (2005) en aquellos países que la realizan, cuenta con normas oficiales las cuales difieren notablemente entre sus clases y el valor de los parámetros para cada una de estas. Las normas de mayor uso y reporte en investigaciones relacionadas al marmoleado son la estadounidense y la japonesa (Liu, Ngadia, Prashera y Gariépy, 2012; Lozano y Méndez, 2005). Sin embargo; tomando en cuenta lo referido por Jackman, Sun, Du y Allen (2009) con respecto al

---

análisis de la calidad de la carne de res mediante jueces entrenados, esta evaluación es subjetiva, tediosa, laboriosa y costosa. Por lo tanto; se hace necesario desarrollar métodos objetivo de evaluación de vetas de grasa para la industria cárnica (Xiong y col., 2014).

En el camino al desarrollo de nuevos métodos para la evaluación del marmoleado se han propuesto la visión artificial como herramienta para evaluar de manera objetiva el marmoleado en carne de vacuno (Shiranita, Hayashi, Otsubo, Miyajima y Takiyama, 2000; Tan, 2004; Toraichi, Kwan, Sugiyawa, Wada y Mitsumoto, 2002; Yoshikawa, Toraichi, Otsu, Nakai y Mitsumoto, 2000) y recientemente la técnica de imágenes hiperespectrales, donde ha demostrado ser rápida, objetiva y no tener efectos destructivos sobre el producto (Elmasry y col., 2012; Muñoz, Rubio-Celorio, Garcia-Gil, Guàrdia y Fulladosa, 2015; Ngapo, Riendeau, Laberge y Fortin, 2012; Tan, 2004; Xiong y col., 2014).

Estas nuevas tecnologías han hecho uso de descriptores o parámetros morfogeométricos de las manchas o acumulaciones de las manchas de grasa, entre los cuales se encuentran los mencionados en la Tabla 6. 1 (Muñoz y col., 2015) y que han sido utilizados previamente por investigadores como Faucitano, Huff, Teuscher, Gariepy y Wegner

(2005); Huang, Liu, Ngadi y Gariépy (2013); Jackman, Sun, Du y Allen, (2009); Peña, Molina, Avilés, Juárez y Horcada (2013); entre otros.

Tabla 6. 1 Descriptores usados en la evaluación de marmoleo

Nº	Parámetros	Nº	Parámetros
1	Proporción de acumulaciones de grasa intramuscular (AGI) en relación con la superficie total ROI (%)	16	Longitud media del esqueleto de AGI (cm)
2	Número de AGI	17	Longitud media del esqueleto de las tres mayores AGI (cm)
3	Número de AGI / cm <sup>2</sup>	18	Proporción de la longitud de los esqueletos de los tres mayores AGI en relación a la longitud total de AGI (%)
4	Superficie promedio de AGI (cm <sup>2</sup> )	19	Suma de la longitud de los esqueletos de los tres más grandes AGI (cm)
5	Longitud media de AGI (cm)	20	Proporción de AGI con tamaño igual o menor que 20 píxeles en relación con el área total (%)
6	Longitud media de las AGI (cm)	21	Proporción de AGI con tamaño igual o menor que 20 píxeles en relación en relación con el área total de AGI (%)
7	Longitud media de las AGI para las tres áreas más grandes de grasa (cm)	22	Proporción del número de manchas FMI zona con tamaño igual o menor de 20 píxeles en relación con el número total de FMI manchas (%)
8	Grosor media de las AGI para las tres áreas más grandes de grasa (cm)	23	La mayor distancia promedio de un punto dentro de la AGI a la frontera (cm)
9	Suma de la longitud de las AGI (cm)	24	La distancia más grande promedio de un punto dentro de la AGI a la frontera de las tres áreas más grandes de grasa (cm)
10	Suma del grosor de las AGI (cm)	25	Proporción de la distancia más grande de las tres mayores AGI con relación a la suma de las distancias más grandes para todas las AGI (%)
11	Suma de la longitud de los tres mayores AGI (cm)	26	Suma de la distancia más grande desde un punto dentro de la AGI a la frontera de las tres áreas más grandes de grasa (cm)
12	Suma de la anchura de las tres mayores AGI (cm)	27	Número promedio de puntos de intersección del esqueleto
13	Proporción de la longitud de las tres mayores AGI en relación con la longitud total de todas las AGI (%)	28	Número promedio de puntos de intersección del esqueleto de las mayores AGI
14	Proporción del ancho de las tres mayores AGI en relación con el ancho total de todas las AGI (%)	29	Proporción de los puntos de intersección del esqueleto de tres más grandes AGI en relación con el número total de puntos de intersección (%)
15	Proporción del área de las tres mayores AGI en relación con el área total de todas las AGI (%)	30	Suma del número total de puntos de intersección de los tres más grandes AGI

Fuente: Muñoz, Rubio-Celorio, Garcia-Gil, Guàrdia y Fulladosa (2015)

Sin embargo; se requiere previamente diferenciar las AGI del tejido intramuscular, esto se ha realizado utilizando una diversidad de diversidad de métodos e imágenes (Tabla 6. 2); cómo se observa el método más usado ha sido la segmentación por umbralizado y el tipo de imagen la RGB.

Tabla 6. 2 Clasificadores usados en el análisis de marmoleado

<b>Tipo de Imagen</b>	<b>Método</b>	<b>Fuente</b>
Hiperspectral (NIR)	– Segmentado por umbralizado	Liu y Ngadi (2014)
RGB	– Maquinas soportadas en vectores – Redes neuronales	Muñoz, Rubio-Celorio, Garcia-Gil, Guàrdia, y Fulladosa (2015)
RGB	– Segmentado por umbralizado	Liu, Ngadia, Prashera, y Gariépy (2012)
RGB	– Segmentado por umbralizado	Jackman, Sun, y Allen (2010)
RGB	– Matriz de coocurrencia de nivel de grises – Red neuronal lineal – Perceptron multicapa MLP (MultiLayer Perceptron)	Huang, Liu, Ngadi, y Gariépy (2013)
Ultra sound	– Red neuronal de function radial RBF (Radial Basis Function) – Red neuronal probabilistic PNN (Probabilistic Neural Network)	Przybylak y col. (2016)

Por tanto; dada a la poca información del uso de perfiles espectrales en el reconocimiento de las AGI se ha planteado como objetivo de este capítulo el desarrollar una metodología para la determinación de las AGI en carne de res, utilizando la tecnología de imágenes hiperespectrales; a fin de aplicarlo en la determinación del marmoleado usando algunos de los descriptores comentados anteriormente.

## 6.2. Material y métodos

### 6.2.1. Muestras biológicas

Se utilizaron 35 muestras del musculo *longissimus dorsi* (LD) de reses beneficiadas en el centro de beneficio municipal de la ciudad de Chachapoyas, Amazonas, Perú. Estas muestras fueron extraídas entre la sexta y séptima costilla (Figura 6. 1) en carcasa a las 24 horas post-mortem del animal.

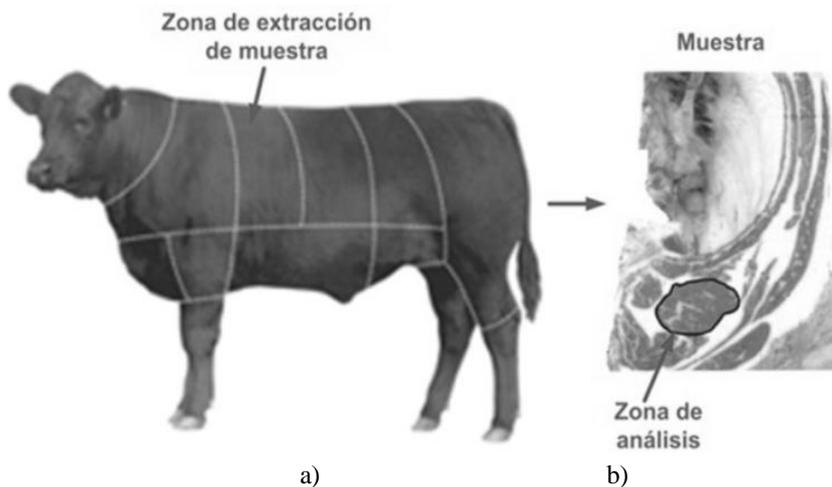


Figura 6. 1 a) Ubicación de zona de extracción de muestra, b) Zona de análisis en la muestra.

Fuente: Adaptado de American Angus Association (2007) y Devine y Dikeman (2014)

Las muestras se almacenaron en bolsas de polietileno de alta densidad, se transportaron en cajas de hielo al laboratorio, donde se congelaron a  $-18^{\circ}\text{C}$  en un refrigerador-congelador durante 24 horas. Posteriormente fueron cortadas en secciones de 2 cm de espesor mediante una cortadora

industrial. Por último; previo a la adquisición de las imágenes hiperespectrales, las muestras se descongelaron a temperatura constante de 2 °C durante 24 horas.

### 6.2.2. Metodología

La metodología experimental se muestra en la Figura 6. 2 y los apartados principales se detallan en los siguientes párrafos.

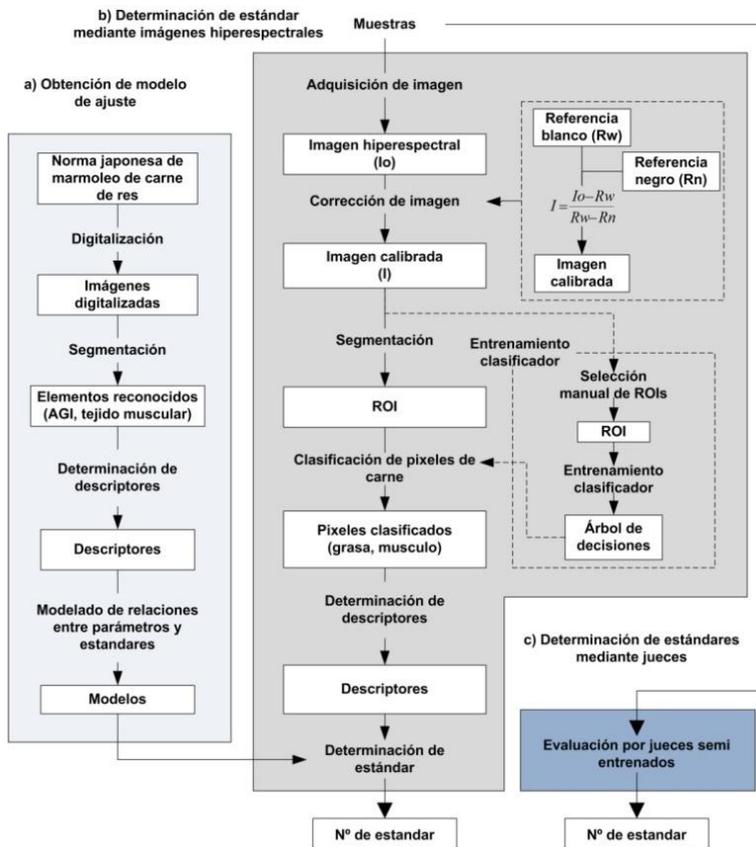


Figura 6. 2 Principales pasos de la metodología experimental para estudio de marmoleo por la tecnología d imágenes hiperespectrales

## **A. Obtención de modelo de ajuste**

El modelo de ajuste requirió digitalizar los estándares de la norma japonesa, a fin de extraer los descriptores de los parámetros morfogeométricos de las AGIs, y a partir de estos modelar la relación existente las AGIs y la clase a la que le pertenecen. Asimismo fueron caracterizadas las muestras a ser escaneadas mediante sus parámetros físicos y fisicoquímicos. Los detalles de cada paso en esta etapa se describen a continuación:

### **A.1 Caracterización de las muestras**

Cada una de las muestras fue escaneada por el sistema de imágenes hiperespectrales, ubicándolas en el sistema como se comenta en el Capítulo II, apartado 2.5. Posteriormente; se caracterizó cada muestra en términos de, pH, acidez, humedad y color, usando para este fin los métodos y equipos mencionados en la Tabla 6.3.

Tabla 6. 3 Métodos y equipos para caracterización de muestras

<b>Parámetro físicoquímico</b>	<b>Método</b>	<b>Equipo</b>	<b>Fuente</b>
Color	Colorímetro	Colorímetro (JZ-300, Shenzhen Kingwell Instruments Co., China)	AMSA (1992)
pH	pHmetro	pH-metro (HI 2213 pH/ORP, Hanna Instruments Inc., USA.)	Braña y col. (2011)
Acidez	Titulación	- - -	Ponce y Pérez (2013)
Humedad	Gravimetría	Balanza analítica (PA214, Ohaus Corporation, USA) Estufa Ecocell (EC 55, MMM Group, USA).	Braña y col. (2011)

## **A.2 Extracción de descriptores de la norma japonesa de marmoleado**

La norma japonesa para evaluación del grado de marmoleado de carne de res – BMS (Beef Marble Score) clasifica el marmoleado, de acuerdo a la presencia y distribución de las AGI, en 5 grados y 12 números BMS; la representación grafica para cada uno de los grados se muestra en la Figura 6. 3 y el resumen de los mismos en la Tabla 6. 4.

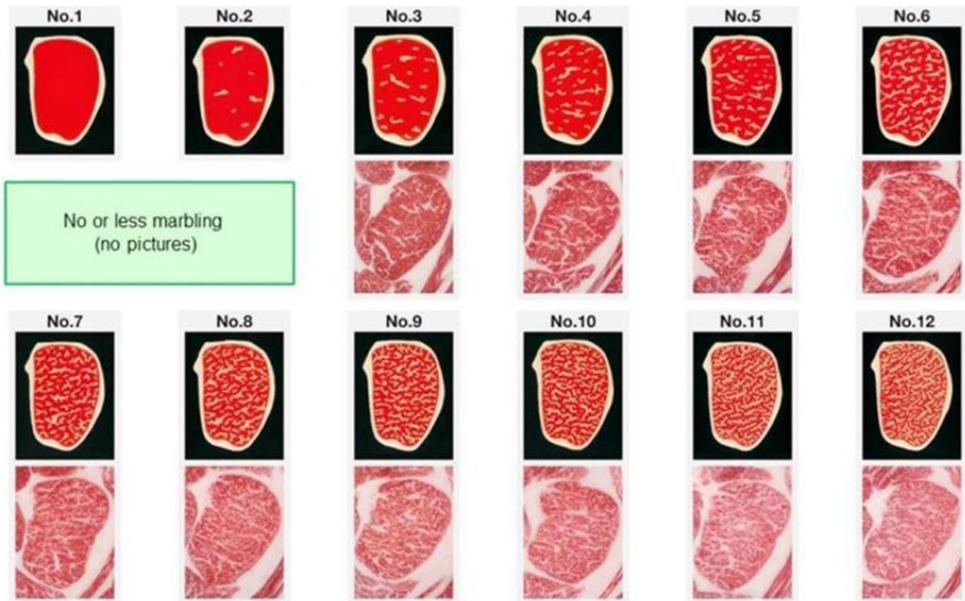


Figura 6. 3 Estándares de marmoleo de la carne (BMS) de la norma Japonesa  
 Fuente: Gotoh, Takahashi, Nishimura, Kuchida y Mannen (2014)

Según esta norma este atributo debe medirse entre la sexta y séptima costilla, en la sección izquierda de la canal (Devine y Dikeman, 2014; Gotoh y col., 2014).

Tabla 6. 4 Clasificación del grado de marmoleo japonés de res

BMS		GRADO
1	1	Pobre
2	2	Por debajo del promedio
3-4	3	Promedio
5-7	4	Bueno
8-12	5	Excelente

Fuente: Devine y Dikeman (2014)

### A.3 Digitalización de la norma japonesa de marmoleo de carne

La representación grafica de cada uno de los doce estándares BMS, Figura 6. 3, fueron digitalizados siguiendo la secuencia lógica de la Figura 6. 4

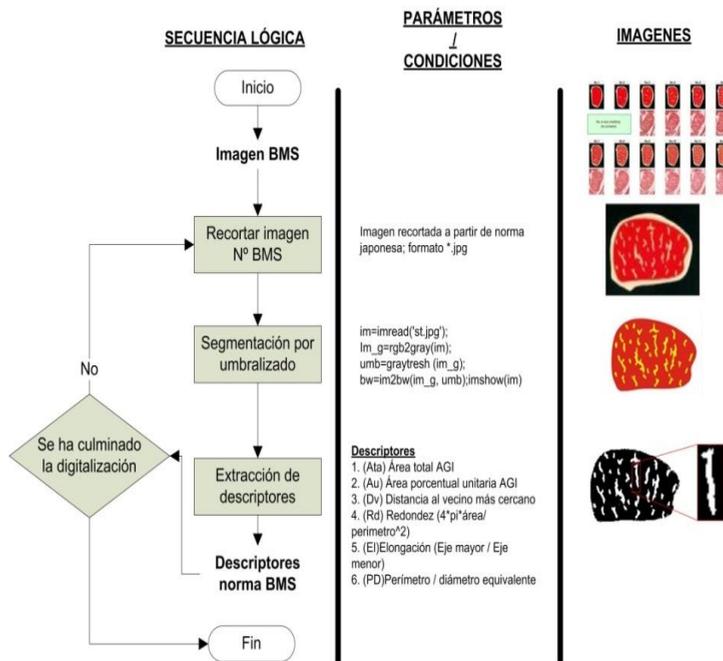


Figura 6. 4 digitalización de norma japonesa de marmoleo de carne de res

La digitalización de cada estándar de la norma se realizó cargando cada imagen y segmentando por umbralizado, obteniendo tanto la información de fondo, AGI y tejido muscular (TM) mediante el comando *regionprops*.

Posteriormente; se seleccionaron los siguientes descriptores:

- 
- Área total AGI (Ata)
  - Área porcentual unitaria AGI (Au)
  - Distancia al vecino más cercano (Dv)
  - Redondez (Rd)
  - Elongación (El)
  - Relación perímetro / diámetro equivalente (PD).

La secuencia lógica para la digitalización y extracción de información se implemento en script de MATLAB 7.1

#### **A.4 Modelado de relación entre descriptores y clases**

Los descriptores extraídos para las AGI, para cada estándar de la norma, se correlacionaron con sus respectivas clases mediante Regresión Lineal Múltiple (RLM) generando una función para determinación la clase final y la significancia de cada descriptor en la determinación de la clase.

#### **B. Determinación de estándares mediante imágenes hiperespectrales**

Paralelamente a la obtención del modelo se obtuvieron imágenes de las diferentes muestras del musculo *longissimus dorsi*; fueron cargadas, corregidas y a partir de estas, mediante el software desarrollado para la presente tesis, se extrajo la información espectral de cada pixel para su

posterior clasificación. Como paso final de esta etapa se determinan los descriptores de las AGIs.

### **B.1 Adquisición y corrección de imagen hiperespectrales**

La imagen de cada muestra se adquirió y corrigió espacialmente de acuerdo al Capítulo 2, apartados 2.4 y 2.5, haciendo uso del sistema de adquisición de imágenes hiperespectrales y el software Spectronon 2.6.2.

### **B.2 Entrenamiento de clasificador**

Fueron seleccionadas 10 imágenes al azar de entre las 35 imágenes adquiridas a las muestras; seleccionando manualmente a partir de estas imágenes diferentes secciones o ROIs. Este proceso se realizó mediante el módulo de determinación de marmoleo en carne de res del software desarrollado en el Capítulo III, apartado 3.3.5. Mediante este sistema se extrajeron perfiles espectrales de AGI y tejido muscular; posteriormente estos fueron corregidos mediante el filtro Savosky-Golay y se retiraron los espectros anómalos. Finalmente se procedió a entrenar un árbol de decisiones con los espectros corregidos; grabando la estructura de clasificación, a la cual nos referiremos posteriormente como árbol en formato \*.m

### **B.3 Segmentación y clasificación de píxeles**

La segmentación de las 20 muestras en las cuales se aplicó el clasificador se realizó automáticamente por el método de umbralizado; de acuerdo a lo explicado en el Capítulo II y para lo cual se usó la rutina de segmentación del software. Posteriormente cada píxel de la ROI fue clasificado mediante el árbol de decisiones entrenado en el paso anterior; clasificándolos en AGI y tejido Muscular (TM)

### **B.4 Determinación de descriptores y clasificación automática de la muestra.**

Clasificados los píxeles de la ROIs, en cada una de las diferentes muestras, se obtuvo la información de los descriptores con la cual calcula la clase, según la norma japonesa, mediante el modelo desarrollado en el Ítem A.4 de la presente sección.

### **C. Determinación de estándares mediante jueces**

Las muestras de carne fueron clasificadas mediante un panel de jueces semientrenados, conformado por 23 estudiantes del IX semestre de Ingeniería Zootecnista de la Universidad Nacional Toribio Rodríguez de Mendoza; previamente capacitados en el curso de tecnología de carnes.

## 6.3. Resultados y discusión

### 6.3.1. Caracterización de las muestras

En la Tabla 6. 5 se muestran los valores promedio obtenidos para los principales parámetros fisicoquímicos evacuados en las muestras.

Tabla 6. 5 pH, color, acidez y humedad de las muestras

Estadístico	pH	Acidez (% de ácido láctico)	Humedad (%)	Color		
				L*	a*	b*
Media	5.74	0.049	73.95	30.65	11.55	5.62
Desviación estándar	0.13	0.009	1.54	1.92	1.55	1.12
Rango	0.61	0.039	5.15	10.05	5.75	4.60
Mínimo	5.54	0.027	70.74	25.10	9.30	3.75
Máximo	6.12	0.065	75.89	35.15	15.05	8.35

El pH presentó un valor promedio de 5.74; este valor concuerda con lo reportado por Braña y col. (2011), quienes mencionan que a las 24 horas post-mortem el pH fluctúa entre 5.4 y 5.9. Asimismo; Elmasry y col. (2012), reportaron, en un estudio realizado con 321, valores de pH promedio de 5.58 en carne a las 48 horas post-mortem. En cuanto a la acidez de las muestras se observó valores más altos en las muestras con pH por debajo del promedio, esto se debería a la degradación del glucógeno a ácido láctico (Braña y col., 2011) por los métodos de mantenimiento del ganado previo al proceso de beneficio.

Con respecto al color de las muestras se obtuvieron valores promedio de 30.65, 11.55 y 5.62 para L, a\* y b\* respectivamente, valores cercanos a los reportados por Elmasry y col. (2011) 33.70, 18.16 y 6.97 respectivamente y cuyas diferencias se deberían, de acuerdo a lo propuesto por Honikel (1998), al contenido de mioglobina, la cual depende de factores de producción primaria (raza, edad y estado nutricional), condiciones previas al sacrificio, proceso de beneficio y el procesamiento posterior.

Por otro lado los valores de humedad Braña y col. (2011) y ElMasry, Sun, y Allen (2013) reportaron contenidos promedio similares de agua entre 70 y 75%; por cuanto la humedad de las muestras se encontró dentro de los rangos reportados previamente.

Así, los parámetros de acidez, humedad y pH afectan el color de las muestras, acelerando o disminuyendo la velocidad de oxidación de la mioglobina; por tanto, debe asociar la medición de color con los parámetros previamente mencionados (Braña y col., 2011).

### 6.3.2. Análisis de parámetros estadísticos de vetas de grasa en norma japonesa

En la Figura 6. 5 se muestran las imágenes digitalizadas obtenidas de cada uno de los estándares de la norma japonesa de marmoleado, en formato \*.JPEG.

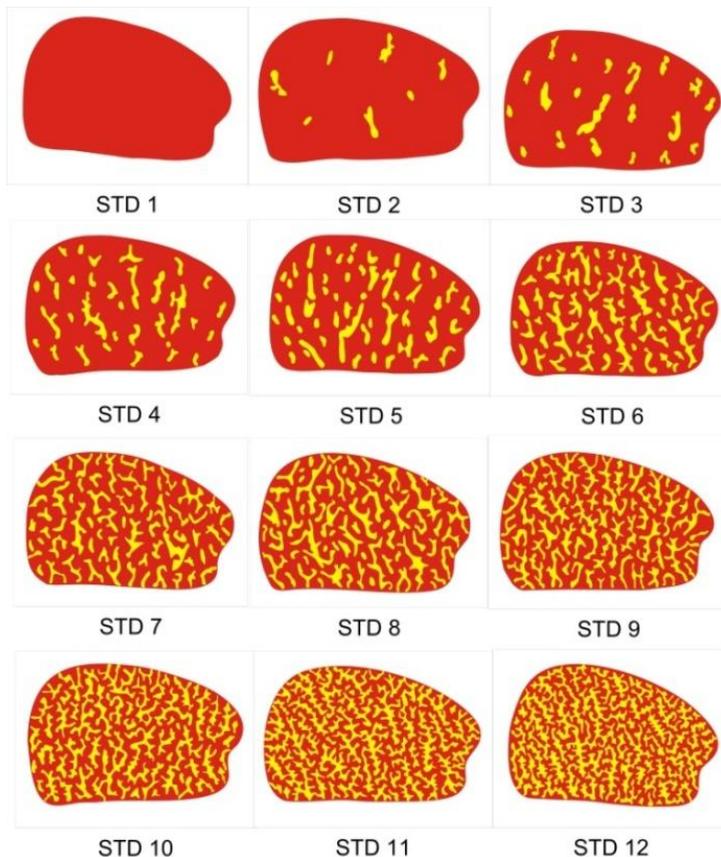


Figura 6. 5 Imágenes resultante de la digitalización de los estándares de la norma japonesa de marmoleado mediante el software Matlab 2010<sup>a</sup>

Asimismo; la Tabla 6. 7 muestra el resultado de los valor promedio en los descriptores seleccionados para las AGIs, para cada estándar de la norma japonesa.

Tabla 6. 6 Valor\* promedio de descriptores de las AGIs extraídas de la norma japonesa

Clase	Área grasa (%)		Distancia media relativa	Redondez	Elongación	Per / Deq
	Total	Cumulo				
2	2.64	14.29	0.264	0.48	3.24	4.79
3	7.52	5.00	0.161	0.47	2.78	4.82
4	10.93	3.03	0.114	0.48	2.80	4.92
5	16.14	1.92	0.090	0.56	2.64	4.42
6	21.56	1.89	0.088	0.39	2.49	5.59
7	22.95	1.54	0.083	0.33	2.75	6.04
8	26.64	1.54	0.077	0.35	2.73	6.19
9	26.85	1.89	0.084	0.21	2.68	7.90
10	30.19	1.89	0.081	0.23	2.51	7.93
11	33.91	2.38	0.097	0.18	2.42	9.75
12	35.16	2.38	0.073	0.25	2.53	8.68

\* Las unidades de los descriptores se fijaron en unidades relativas, evitando usar unidades influenciadas por la distancia entre el lente y la muestra

A partir de estos resultados se modelaron, por regresión múltiple, los descriptores de las AGI y las correspondientes clases, ecuación 6.1.

$$Clase = -6.96 + 0.23 * Ata + 0.03 * Au - 2.20 * Dv + 5.93 * Rd - 0.12 * El + 1.14 * PD \dots Ec. 6.1$$

Dónde:

*Ata* = sumatoria de las áreas de las betas de grasa

*Au* = Área unitaria mediana

*Dv* = Distancia mínima normalizada mediana al vecino más cercano

*Rd* = Redondez mediana

*El* = Elongación mediana

*PD* = relación mediana perímetro/ diámetro.

El modelo resultante alcanzo un coeficiente de correlación ( $R^2$ ) de 0.99 y un  $R^2$  ajustado de 0.989. Posteriormente; se determinaron los estadísticos para el efecto de los descriptores en el modelo (Tabla 6. 7).

Tabla 6. 7 Estadísticos de la regresión múltiple para cada descriptor del modelo de regresión multiple

Parámetro	Coeficientes	Error típico	Estadístico	
			T	Valor-P
<b>Ata</b>	0.2339	0.0773	3.0241	0.0390*
<b>Au</b>	0.0387	0.2174	0.1781	0.8673
<b>Dv</b>	-2.2054	14.9660	-0.1474	0.8900
<b>Rd</b>	5.9311	5.7896	1.0244	0.3635
<b>El</b>	0.1228	1.7637	0.0696	0.9479
<b>PD</b>	1.1447	0.4528	2.5281	0.0648

*\* Parámetros de mayor efecto estadísticamente significativo en la ecuación.*

Como se aprecia en la tabla anterior el descriptivo de mayor influencia estadística (95 % de nivel de confianza) es el Ata; esto es concordante con lo reportado por Muñoz y col. (2015).

En este sentido se generalizo un modelo utilizando la Sumatoria de las aéreas de las betas de grasa y obteniendo con este la ecuación 6.2 y sus estadísticos en la Tabla 6.8.

$$Clase = 1.799 + 0.118 * Ata + 0.005 * At^2..Ec. 6.2$$

Tabla 6. 8 Estadísticos de la regresión polinómica

Parámetro	Estimación	Error Estándar	Estadístico	
			T	Valor-P
Constante	1.799	0.404	4.451	0.002
Ata	0.118	0.047	2.511	0.036
Ata <sup>2</sup>	0.005	0.001	4.017	0.003

Según los Valor-P de

---

Tabla 6. 8 ambos términos tienen efecto estadísticamente significativo con un nivel de confianza del 95 %, un  $R^2$  de 0.99 y  $R^2$  ajustado de 0.99. Por tanto; a diferencia de los trabajos de Albrecht, Wegner y Ender (1996); Cortéz (2005); Péres, García, Diéguez y Tosar (2013), se propone que el utilizar una ecuación ajustada en base al área promedio ocupada por la grasa es un método aceptable para la clasificación del marmoleo de carne de res.

### **6.3.3. Extracción de información espectral**

Fueron obtenidos 21 402 perfiles espectrales, 10 905 de AGI y 10 497 de TM; estos espectros, luego de la corrección por filtrado y retiro de espectros anómalos, se redujeron a 5388 espectros de AGI y 4 760 espectros de tejido muscular. En la Figura 6.6 se muestran tanto los perfiles espectrales promedio así como sus límites superiores e inferiores, considerando de acuerdo a la desviación estándar.

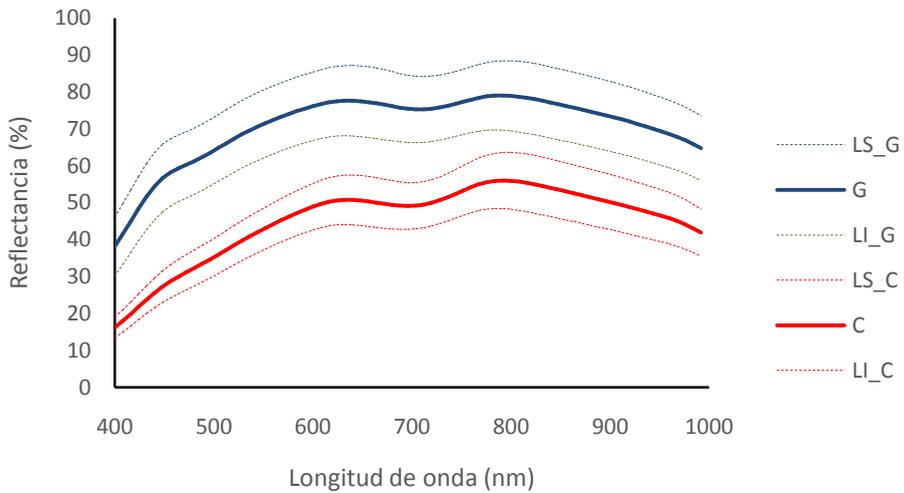


Figura 6. 6 Espectros promedio de reflectancia de los píxeles de carne (C) y grasa (G), límite superior (LS), límite inferior (LI).

La Figura 6.6 muestra que existen diferencias entre los perfiles espectrales de las AGIs y el TM, observándose que no existe traslapamiento entre sus perfiles. Esto se realizó en forma similar a lo realizado por Nogales-Bueno y col. (2014) quienes comparando los perfiles espectrales de dos variedades de uva, amplificando su dominio en +/- 10 veces la desviación estándar a lo largo de las longitudes de que constituyeron cada perfil. En tal sentido se determina que a 400 nm se presenta la máxima diferencia entre los espectros de tejido muscular y AGIs. A partir de este resultado se procedió a generar el clasificador, de tipo árbol de decisiones, cuya estructura se muestra en la Figura 6.7.

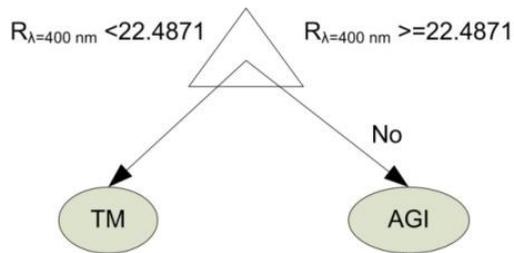


Figura 6. 7 Árbol de decisiones para la clasificación de píxeles en imágenes de carne de res

El árbol de decisiones clasificó con éxito el 99.91 % de los datos espectrales durante el entrenamiento del sistema y se muestra en la Figura 6.7. Su aplicación en la clasificación de los píxeles de la ROI permitió la binarización, asignándole el valor “0” a los píxeles clasificados como TM y “1” a los clasificados como AGI. En la Figura 6.8 se muestra un ejemplo de imagen inicial, intermedia y resultante para una de las muestras en la cual se aplicó tanto la segmentación como la clasificación mediante al árbol de decisiones.

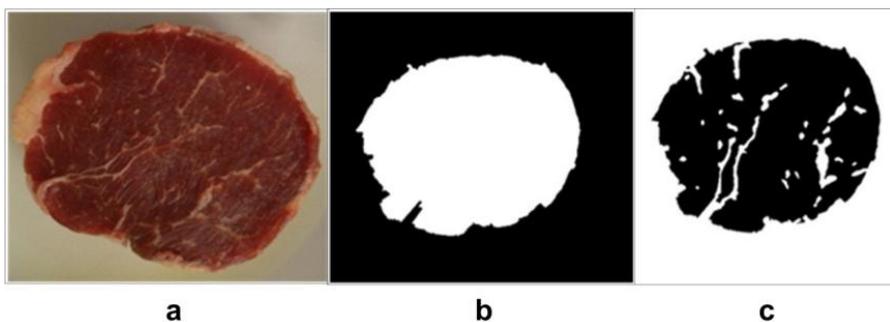


Figura 6. 8(a) Foto en RGB de la muestra 9, (b) segmentación de la muestra, (c) imagen binarizada.

---

Obtenida la imagen *c* de la Figura 6.8 se utilizó el comando *regionprops* para extraer los parámetros en estudio de las AGIs. Esta parte de la metodología tomo en cuenta lo reportado por Dinç y col. (2015) sobre los problemas de la segmentación por umbralizado, para el reconocimiento de las AGI. En este sentido determinaron que dicha técnica por sí sola no genera buenas imágenes binarias para todas las muestras; debido principalmente a la inadecuada selección del umbral cada imagen y propone que la segmentación use otros métodos a fin de superar esta limitación. Por tanto; en la presente investigación, la binarización de la región de interés se basó en el árbol de decisiones detallado previamente.

Finalmente, se utilizó el descriptor *Ata* para determinar la clase de las muestras en base a la Ecuación 6.2 propuesta en el análisis de los parámetros estadísticos, subsección 6.3.2 del presente capítulo.

#### **6.3.4. Resultados de la clasificación de marmoleado de las muestras**

Los resultados de la clasificación de las muestras de carne mediante el software de procesamiento y análisis desarrollado en el Capítulo III y el panel de jueces semientrenados se muestran en la Figura 6.9.

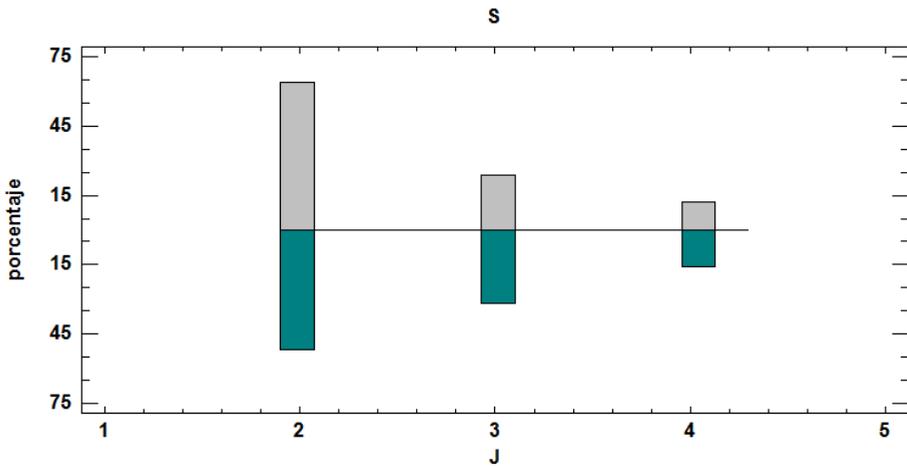


Figura 6.9 Distribucion de clases obtenidos mediante el software (S) y panel de jueces (J).

Los resultados de la evaluación mediante jueces y los valores predichos por el sistema, fueron analizados mediante la prueba de normalidad de los datos, Kolmogorov-Smirnov obteniendo un valor de  $p = 0.000$ . Dado que los datos no siguen una distribución normal se aplicó una prueba no paramétrica para 2 muestras independientes (Mann-Whitney) el cual arroja indican un valor  $p=0.324$ , estableciendo que no hay diferencia estadística significativa entre el sistema desarrollado y el sistema de visión por jueces.

Qiao y col. (2007) empleó por primera vez las normas de marmoleado para la evaluación objetiva de las puntuaciones de marmoleado. Las normas de marmoleado fueron digitalizadas y índices de la imagen de

textura fueron extraídos de las imágenes digitalizadas por la matriz de co-ocurrencia Shiranitay col., 1998. En los últimos años trabajos como el de Li y col., (2011) evaluaron el nivel de marmoleado en carne de res usando un sistema de imágenes hiperespectrales de exploración en la región espectral de 400-1100 nm. Las imágenes a 530 nm se utilizaron para diferenciar el nivel de marmoleado de muestras de carne. Con tres parámetros característicos extraídos (área grasa de la partícula grande, área grasa partícula media y área grasa de las partículas pequeñas), un modelo de predicción Regresión lineal múltiple (MLR) fue finalmente establecido, lo que dio un resultado alentador con  $R^2 = 0.92$ . Los resultados indicaron que a través de una regresión lineal múltiple, la carne de res se puede clasificar en base a los parámetros característicos de marmoleado de res de una mejor manera.

#### **6.4. Conclusiones**

- El número de estándar de la norma japonesa puede relacionarse con los descriptores de las AGIs mediante un modelo de regresión lineal, basado en la sumatoria de las áreas de grasa.

- Las diferencias entre los perfiles espectrales posibilita la clasificación de píxeles en AGis y TM, mediante un árbol de decisiones basado y sus valores de intensidad a 400 nm.
- La metodología implementada probó ser válida para clasificar el marmoleado de carne de res en base a la norma japonesa de marmoleo de carne de res.

## Referencias bibliográficas

- Albrecht, E., Wegner, J., y Ender, K. (1996). A New Technique for Objective Evaluation of Marbling in Beef, 76, 1145–1148.
- American Angus Association. (2007). Tabla de cortes Angus en español.
- AMSA. (1992). Guidelines for meat color evaluation. Chicago - USA: National Association Live Stock and Meat Board.
- Braña, D., Ramirez, E., Rubio, M., Sánchez, A., Torrescano, G., Arenas, M., ... Gerardo, F. (2011). Manual de análisis de calidad en muestras de carne. México: Centro Nacional de Investigación Disciplinaria en Fisiología y Mejoramiento Animal.
- Cortéz, J. (2005). Caracterización del ganado bovino sacrificado en el rastro municipal de la ciudad de Chihuahua (Tesis de maestría). Universidad Autónoma de Chihuahua, Chihuahua - México.
- Devine, C., y Dikeman, M. (2014). Encyclopedia of Meat Sciences. Vol. 3ro. Elsevier.
- Elmasry, G., Barbin, D., Sun, D. y Allen, P. (2012). Meat quality evaluation by hyperspectral imaging technique: an overview. Food Science and Nutrition, 52, 689–711.

- 
- Elmasry, G., Iqbal, A., Sun, D., Allen, P. y Ward, P. (2011). Quality classification of cooked, sliced turkey hams using NIR hyperspectral imaging system. *Journal of Food Engineering*, 103, 333–344.
  - ElMasry, G., Sun, D. y Allen, P. (2013). Chemical-free assessment and mapping of major constituents in beef using hyperspectral imaging. *Journal of Food Engineering*, 117, 235–246.
  - Faucitano, L., Huff, P., Teuscher, F., Gariépy, C. y Wegner, J. (2005). Application of computer image analysis to measure pork marbling characteristics. *Meat Science*, 69(3), 537–543.
  - Gotoh, T., Takahashi, H., Nishimura, T., Kuchida, K., y Mannen, H. (2014). Meat produced by japanese black cattle and wagyu. *Animal Frontiers*, 4(4), 46–54.
  - Honikel, K. (1998). Reference Methods for the Assessment of Physical Characteristics of Meat. *Meat Science*, 49(4), 447–457.
  - Huang, H., Liu, L., Ngadi, M. O. y Gariépy, C. (2013). Prediction of pork marbling scores using pattern analysis techniques. *Food Control*, 31(1), 224–229.
  - Jackman, P., Sun, D. y Allen, P. (2010). Prediction of beef palatability from colour, marbling and surface texture features of longissimus dorsi. *Journal of Food Engineering*, 96(1), 151–165.

- 
- Jackman, P., Sun, D., Du, C. y Allen, P. (2009). Prediction of beef eating qualities from colour, marbling and wavelet surface texture features using homogenous carcass treatment. *Pattern Recognition*, 42(5), 751–763.
  - Li, Y., Shan, J., Peng, Y. y Gao, X. (2011). Nondestructive assessment of beef-marbling grade using hyperspectral imaging technology. *New Technology of Agricultural Engineering*, 779–783.
  - Liu, L. y Ngadi, M. (2014). Predicting intramuscular fat content of pork using hyperspectral imaging. *Journal of Food Engineering*, 134, 16–23.
  - Liu, L., Ngadia, M., Prashera, S. y Garíepy, C. (2012). Objective determination of pork marbling scores using the wide line detector. *Journal of Food Engineering*, 110, 497–504.
  - Lozano, M. y Méndez, D. (2005). Evaluación de las canales de bovino a nivel internacional (Informe de investigación). Mexico: Universidad Nacional Autónoma de México - Facultad de Medicina Veterinaria y Zootecnia.
  - McAfee, A., McSorley, E., Cuskelly, G., Moss, B., Wallace, J., Bonham, M. y Fearon, A. (2010). Red meat consumption: an overview of the risks and benefits. *Meat Science*, 1–13.

- Muñoz, I., Rubio-Celorio, M., Garcia-Gil, N., Guàrdia, M. y Fulladosa, E. (2015). Computer image analysis as a tool for classifying marbling: A case study in dry-cured ham. *Journal of Food Engineering*, 166, 148–155.
- Ngapo, T. M., Riendeau, L., Laberge, C. y Fortin, J. (2012). Marbling and ageing — Part 1. Sensory quality of pork. *Food Research International*, 49(1), 396–405.
- Peña, F., Molina, A., Avilés, C., Juárez, M. y Horcada, A. (2013). Marbling in the longissimus thoracis muscle from lean cattle breeds. Computer image analysis of fresh versus stained meat samples. *Meat Science*, 95(3), 512–519.
- Péres, Y., García, J., Diéguez, F. y Tosar, M. (2013). Caracterización de canal y la calidad de la carne de cerdas yorshire y landrace desechadas como reproductoras. *Revista Computadorizada de Producción Porcina*, 20, 322–325.
- Ponce, E. y Pérez, M. (2013). Manual de prácticas de laboratorio de Tecnología de Carnes. México: Universidad Autónoma Metropolitana.
- Przybylak, A., Boniecki, P., Koszela, K., Ludwiczak, A., Zaborowicz, M., Lisiak, D., ...Ślósarz, P. (2016). Estimation of

- 
- intramuscular level of marbling among Whiteheaded Mutton Sheep lambs. *Journal of Food Engineering*, 168, 199–204.
- Shiranita, K., Hayashi, K., Otsubo, A., Miyajima, T. y Takiyama, R. (2000). Grading meat quality by image processing. *Pattern Recognition*, 33, 97–104.
  - Tan, J. (2004). Meat quality evaluation by computer vision. *Journal of Food Engineering*, 61, 27–35.
  - Toraichi, K., Kwan, P., Sugiyawa, T., Wada, K. y Mitsumoto, M. (2002). On a fluency image coding system for beef marbling evaluation. *Pattern Recognition*, 23, 1277–1291.
  - Xiong, Z., Sun, D., Zeng, X. y Xie, A. (2014). Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: A review. *Journal of Food Engineering*, 132, 1–13.
  - Yoshikawa, F., Toraichi, K., Otsu, O., Nakai, H., y Mitsumoto, M. (2000). On a grading system for beef marbling. *Pattern Recognition Letter*, 21.

=====

## **7. Anexos**

=====

## A.1 Código fuente del software de pre-procesamiento y análisis de imágenes hiperespectrales

En las siguientes páginas se muestra en detalle el código fuente del software Hyper\_1, desarrollado como parte del Capítulo III y utilizado como herramienta para la aplicación de la tecnología de imágenes hiperespectrales a la evaluación de la calidad de productos agroalimentarios de la región Amazonas (Perú). Las ventanas o Guides con que el usuario interactúa se muestran en Figuras A.1, A.2 y A.3 y precede al código de las diferentes rutinas que los constituyen.

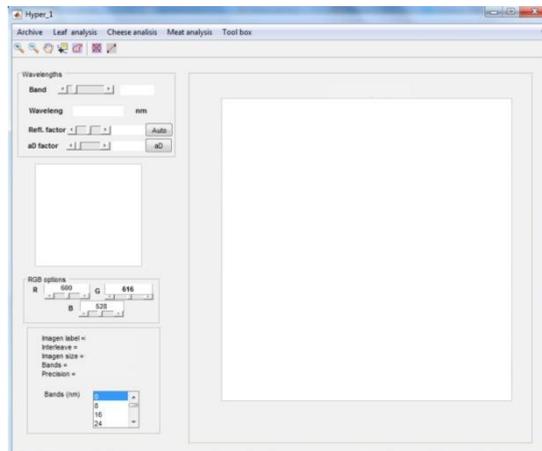


Figura A. 1 Guide Hyper\_1

```
%=====
% GUIDE: Hyper_1.fig / Hyper_1.m
% AUTOR: WILSON MANUEL CASTRO SILUPU
%=====
%Funciones de creacion de guide

function varargout = Hyper_1(varargin)

gui_Singleton = 1;
```

---

```
gui_State = struct('gui_Name',    mfilename, ...
                  'gui_Singleton', gui_Singleton, ...
                  'gui_OpeningFcn', @Hyper_1_OpeningFcn, ...
                  'gui_OutputFcn', @Hyper_1_OutputFcn, ...
                  'gui_LayoutFcn', [], ...
                  'gui_Callback', []);

if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end

% Acciones al abrir el guide

function Hyper_1_OpeningFcn(hObject, ~, handles, varargin)

% inicializar variables del programa

Ini_Var

% asignacion de ejes

axes(handles.ax_rgb); axis off; cla

axes(handles.ax_im); cla

% actualiacion del manejador
```

---

```
handles.output = hObject;

guidata(hObject, handles);

%Salidas de las funciones

function varargout = Hyper_1_OutputFcn(~, ~, handles)

varargout{1} = handles.output;

%Cargar imagen

function btn_abrir_Callback(hObject, eventdata, handles)

abrir_image(handles)

%Cerrar guide

function btn_close_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global message

%opciones al cierre

h=questdlg('Really you want to close the software',message);

%consulta si cerraremos el guide

if strcmp(h,'Yes')==1

    close all

else

    msgbox('The software still be running', message)

end

%Sliders RGB
```

---

```
function sld_r_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global nBandas imagen info

%cargar bandas

banda_r=round(get(hObject,'Value'));

banda_r=nBandas(banda_r,1);

set(handles.txt_r,'String', round(banda_r))

indRGB(1)=round(get(hObject,'Value'));

indRGB(2)=round(get(handles.sld_g,'Value'));

indRGB(3)=round(get(handles.sld_b,'Value'));

%mostrar imagen en RGB

mostrarRGB(handles,indRGB,imagen,info)
```

```
function sld_g_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global nBandas imagen info

%cargar bandas

banda_g=round(get(hObject,'Value'));

banda_g=nBandas(banda_g,1);

set(handles.txt_g,'String', round(banda_g))

indRGB(1)=round(get(handles.sld_r,'Value'));

indRGB(2)=round(get(hObject,'Value'));

indRGB(3)=round(get(handles.sld_b,'Value'));

%mostrar imagen en RGB
```

---

```
mostrarRGB(handles,indRGB,imagen,info)

function sld_b_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global nBandas imagen info

%cargar bandas

banda_b=round(get(hObject,'Value'));

banda_b=nBandas(banda_b,1);

set(handles.txt_b,'String', round(banda_b))

indRGB(1)=round(get(handles.sld_r,'Value'));

indRGB(2)=round(get(handles.sld_g,'Value'));

indRGB(3)=round(get(hObject,'Value'));

%mostrar imagen en RGB

mostrarRGB(handles,indRGB,imagen,info)

%Determinacion automatica de Reflectancia

function autoRF_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global nBandas info imagen message im_enuso

%obtencion de reflectancia maxima

reflectancia=zeros(length(nBandas),1);

for i=1:length(nBandas)

    reflectancia(i,1)=max(max(imagen(:,i)));

end
```

---

```
set(handles.txt_rf,'String',round(max(reflectancia)));
%setear slider sld_RF
RFM=round(max(reflectancia))*1.5;
x=1/RFM; y=10/RFM;
set(handles.sld_RF,'Max',RFM) % reflectancia maxima
set(handles.sld_RF,'Min',1) % reflectancia de inicio
set(handles.sld_RF,'Value',round(max(reflectancia)))
set(handles.sld_RF,'SliderStep',[x y])
%cargar la reflectancia en el info de la imagen
info = setfield(info, 'reflectance_scale_factor', round(max(reflectancia)));
%imagen corregida por reflectancia
Banda=round(get(handles.sld_lo,'Value'));
im_enuso=imagen(:,Banda)./info.reflectance_scale_factor;
imshow(im_enuso);
axis xy
%mensaje de fin de calculo de calculo de reflectancia maxima
msgbox('Maximun reflectance calculated', message)

%slider para el factor de reflectancia y previsualizacion de la imagen
function sld_RF_Callback(hObject, eventdata, handles)
%declaracion de variables globales
global imagen nBandas info
%modificacion del valor de reflectancia
reflectancia=get(handles.sld_RF,'Value');
```

---

```

set(handles.txt_rf,'String',round(reflectancia));
info = setfield(info, 'reflectance_scale_factor', round(max(reflectancia)));

%correccion de imagenpor nuevo valor de reflectancia

Banda=round(get(handles.sld_lo,'Value'));

im_enuso=imagen(:,Banda)./info.reflectance_scale_factor; %correccion de imagen

imshow(im_enuso); % mostrar imagen en uso

axis xy %organiza la imagen en cuadrantes cartesianos

%mostrar texto en la imagen

texto=strcat(info.label,'-at-(',num2str(nBandas(1)),')nm');

title(texto)

%#####%Personaliz
zacion de controles para la determinacion de roya

%#####

%Cortado - segmentacion de la imagen y corrección por blanco
function btn_leaf_segmn_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global imagen Puntos centro img_adj n_seg info message im_b

global im_enuso Banda opcHyperl

global b_ref n_ref nBandas img_coBN

%realce de la imagen

axes(handles.ax_im);axis off; cla;%asignacion del foco al axes imagen y limpieza

Banda=round(get(handles.sld_lo,'Value')); %banda para la segmentacion

```

---

```
%obtencion de imagen de intensidad para segmentar y pasar a la imagen en uso
im_b=squeeze(imagen(:, :,Banda))./info.reflectance_scale_factor;

im_enuso=im_b;

save im_b im_b

im_enuso=imadjust(im_enuso,stretchlim(im_enuso,[]));%ajuste por histograma

%binarizacion de la imagen en uso

Tsh=opcHyper1(7); %cargar variable treshold

im_enuso=im2bw(im_enuso,Tsh); %binarizacion

%opcion de correccion con fondo con referencias

im_enuso=imfill(~im_enuso,'holes');%llenado de huecos

se = strel('disk',3);% cerrado de la imagen

im_enuso=imclose(~im_enuso,se);

im_enuso=~im_enuso;

%etiquetado y determinacion de propiedades del elemento mayor

im_enuso=bwlabel(im_enuso); %etiquetado de imagen en blanco y negro

stats=regionprops(im_enuso,'Area','MajorAxisLength','Centroid'); %propiedades

regionprops

allArea = [stats.Area];Amax=max(allArea);

cc = bwconncomp(im_enuso);

idx = find([stats.Area] == Amax);

img_adj = ismember(labelmatrix(cc), idx);

centro=stats(idx).Centroid;%determinacion de centroide

img_adj=imfill(img_adj,'holes'); %llenado de imagen negativa

%Determinacion de elementos de borde
```

---

```
Centroide=regionprops(img_adj,'Centroid');
centro=Centroide.Centroid;
im_lim=bwperim(img_adj);
[r c] = find(im_lim==1);
Puntos=zeros(n_seg,3);
angulos=(1:1:n_seg);
for j=1:n_seg
    for i=1:length(r)
        round(angRC(r(i),c(i),centro));
        if angulos(1,j)==round(angRC(r(i),c(i),centro));
            Puntos(j,1)=c(i);
            Puntos(j,2)=r(i);
            Puntos(j,3)=angulos(1,j);
        end
    end
end
end
%correccion de imagenes por Blanco y Negro de referencias
img_coBN=imagen;
%correccion de imagenes por referencias
if opcHyper1(7)==1 %se realiza la correccion
    for t=1:length(nBandas)
        R_N=img_coBN(:,:,t)-n_ref(:,:,t);
        B_N=b_ref(:,:,t)-n_ref(:,:,t);
        img_coBN(:,:,t)=R_N./B_N;
```

---

```
end

end

img_enuso=img_coBN;

%mostrar imagen y puntos de borde

hold on

    imshow(img_enuso(:,:,Banda)./info.reflectance_scale_factor);

    plot(Puntos(:,1),Puntos(:,2),'*r')

hold off

axis xy

% muestra el cuadro de opciones de imagen para la imagen en uso

set(handles.uip_imagen,'Visible','Off')

set(handles.opt_im_coBN,'Value',1)

% mensaje de fin de etapa de segmentacion

msgbox('End segmentation stage', message)

%Determinacion temprana de roya

function btn_roya_analysis_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global img_enuso info tletra Val img_adj metodo

%asignacion del foco al axes imagen

axes(handles.ax_im);

%crear matriz para mostrar imagen coloreada de la naranja

dim=size(img_adj);%dimensiones de la imagen

clase=zeros(dim(1), dim(2),3);
```

---

```
clase=uint8(clase);

%filas y columnas de la imagen ajustada

[rm cm]=find(img_adj==1);

%determinacion de ondas de la imagen en un rango

ondas=round(sscanf(info.wavelength,'%*c %f'));

rango=[1:1:length(ondas)];

ondas=ondas(rango,1);

%matriz de valores daños en la piel

Valores=zeros(length(rm),1);

%mapa de colores

mapa=[7 100 2;

      201 216 20;

      251 121 15;

      230 107 6;

      115 53 2];

%cargar arbol de decisiones

if metodo(1)==1

    load RNA_leave

elseif metodo(2)==1

    load SVM_leave

elseif metodo(3)==1

    load DT_leave

end

%iniciar proceso de clasificacion
```

---

```
h=waitbar(0,'Please wait...'); %mostrar barra de avance

% analisis de los elementos a lo largo de las filas y columnas seleccionadas

for i=1:length(rm)

    %determinacion del y suavizacion de espectro por savorsky - galoy
    intensidades=sgolayfilt(squeeze(img_enuso(rm(i),cm(i),:)),2,21);

    %normalizando espectro al valor minimo
    minimo=min(intensidades(1:40));
    intensidades=intensidades-minimo;

    indices(1)=minimo;

    indices(2)=max(intensidades(20:55));

    indices(3)=min(intensidades(45:75));

    %obtencion de pendientes
    x=[75:1:83];y=intensidades(x);x=(x-1).*8; p=polyfit(x,y',1);
    indices(4)=p(1);

    x=[88:1:115]; y=intensidades(x); x=(x-1).*8; p=polyfit(x,y',1);
    indices(5)=p(1);

    %relacion entre pendientes
    indices(6)=indices(4)/indices(5);

    %Seleccionando sistema a usar
    p=indices;

    if metodo(1)==1 %redes neuronales
        clase_r = sim(RNA_leave,p'); clase_r = vec2ind(clase_r);
    elseif metodo(2)==1 % SVM
        clase_r = predict(SVM_leave,p);
    end
end
```

---

```
elseif metodo(3)==1% arbol de decisiones
    clase_r=round(eval(DT_leave,p));
end
Valores(i,1)=clase_r;
%cargando valores de mapa de colores
clase(rm(i),cm(i,:))=mapa(clase_r,:);
%mostrar avance
waitbar(i/length(rm))
end
%cerrar barra de avance
close(h)
%mostrar imagen por nueva escalas de color
imshow(clase)
axis xy
set(gca,'XTick',[])
set(gca,'YTick',[])
%mostrar grafico de torta en un nuevo figure
figure;
Val=zeros(5,1);
for i=1:5
    [r c]=find(Valores(:,1)==i);
    Val(i,1)=length(r);
end
suma=sum(Val(:,1));
```

---

```
Val=100*Val/suma;

pie(Val(:,1))

colormap (mapa/255)

%crear leyenda de grafico de torta

if exist('Names') ~= 0

    clear ('Names');

end

Names={ };

Contador=0;

for i=1:5

    if Val(i,1)>0

        Contador=Contador+1;

        if i==1

            Names(Contador,1)={'Nule ':'};

        end

        if i==2

            Names(Contador,1)={'Initial ':'};

        end

        if i==3

            Names(Contador,1)={'Moderade ':'};

        end

        if i==4

            Names(Contador,1)={'Several ':'};

        end

    end

end
```

---

```

    if i==5
        Names(Contador,1)={'Necrotic ':'};
    end

end

end

title(strcat('Number of analysed pixels = ', num2str(length(rm))), 'FontSize', tletra)

legend(Names, 'Location', 'Best', 'Orientation', 'Vertical', 'FontSize', tletra)

msgbox('End of classification stage')

%asignacion del foco al axes imagen

axes(handles.ax_im);

%#####Personaliz
zacion de controles para la determinacion de adulteracion por
%harina de maiz
%#####

%Segmentacion de imagenes de queso fresco

function btn_cheese_segm_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global img_enuso info imagen_1_0 espectro_m n imagen_b bnd_prom espectro

%imagen para realizar la segmentacion

Tsh=0.35; %valor de umbralizacion

Banda=30; %banda correspondiente a 240 nm

imagen_b=squeeze(img_enuso(:,:,Banda))./info.reflectance_scale_factor;

```

---

```
%mejoramiento
im_enuso=imagen_b;
im_enuso=imadjust(im_enuso,stretchlim(im_enuso),[]);
im_enuso=im2bw(im_enuso,Tsh);
im_enuso=imfill(im_enuso,'holes');%eliminacion de huecos
    se = strel('disk',3);
im_enuso=imclose(im_enuso,se); %cerrado de la imagen
im_enuso=bwlabel(im_enuso); %etiquetado de la imagen
stats=regionprops(im_enuso,'Area','MinorAxisLength','Centroid');
allArea = [stats.Area];Amax=max(allArea); %calculo area maxima
    cc = bwconncomp(im_enuso); %determinacion de componentes
    idx = find([stats.Area] == Amax); %busqueda del elemento con area maxima
img_adj = ismember(labelmatrix(cc), idx);%seleccion del elemento con area maxima
centro=stats(idx).Centroid;
Rad=0.50*stats(idx).MinorAxisLength; %radio de 75 % del radio menor de la muestra
dim=size(imagen_b);
imagen_1_0=zeros(dim(1),dim(2));
%dibujando aquellos elementos que estan en el interior
for Y=1:dim(1) % filas o Y
    for X=1:dim(2) % columnas o X
        if img_adj(Y,X)==0
            imagen_b(Y,X)=0;
        else
            d=(X-centro(1))^2+(Y-centro(2))^2;d=sqrt(d);
```

---

```
    if d>=0.90*Rad
        imagen_b(Y,X)=imagen_b(Y,X)+0.4;
    else
        imagen_1_0(Y,X)=1;
    end
end
end

end

%mostrando imagen ROI
nBandas=round(sscanf(info.wavelength,'%*c %f'));
texto=strcat(info.label,'-at-',num2str(nBandas(Banda)),'-nm');
imshow(imagen_b);
axis xy
title(texto, 'FontSize',8)
%crear matriz de datos por imagen
[r c]=find(imagen_1_0==1);
espectro=zeros(info.bands,length(r));
for t=1:length(r)
    espectro(:,t)=squeeze(img_enuso(r(t),c(t),:));
end
%eliminacion de anomalos
bnd_prom=15;
prom=mean(espectro(bnd_prom,:));
dsvst=std(espectro(bnd_prom,:));
```

---

```

LimInf=(prom - dsvst); LimSup=(prom + dsvst);
n=0;
espectro_m=zeros(info.bands,length(r));
for l=1:length(r)
    if (espectro(bnd_prom,l)>LimInf)&&(espectro(bnd_prom,l)<LimSup)
        n=n+1;
        espectro_m(:,n)= espectro(:,l);
    else
        imagen_b(r(l),c(l))=0;
    end
end
end
%mostrar la imagen sin anomalos
texto=strcat(texto,'-eliminada');
nBandas=round(sscanf(info.wavelength,'%*c %f'));
subplot (1,1,1); imshow(imagen_b);
axis xy
title(texto,'FontSize',8)

%Determinacion de adulteracion de muestras
function btn_adulteration_analysis_Callback(hObject, eventdata, handles)
%declaracion de variables globales
global n info texto imagen_b imagen_1_0 bnd_prom espectro
global nBandas tletra img_enuso
%determinacion de espectros a analizar

```

---

```
[r c]=find(imagen_1_0==1);

% mostrar la imagen con partes eliminadas

espectro=zeros(info.bands,length(r));

for t=1:length(r)

    espectro(:,t)=squeeze(img_enuso(r(t),c(t),:));

end

% filtrado Savorsky golay

espectro=sgolayfilt(espectro,2,21);%espectro filtrado por Savorsky Golay, orden 2

espectro=espectro';

espectro_sc=espectro;

%eliminacion de outliers

n=0;

for col=56:126 %Recorer un rango de longitudes de onda para eliminar outliers %126

    media=mean(espectro(:,col));

    Dsv=2*std(espectro(:,col));

    outliers=zeros(length(espectro(:,col)),1);

    for k=1:length(espectro(:,col))

        if espectro(k,col)< media-Dsv || espectro(k,col)> media+Dsv

            n=n+1;

            outliers(k,1)=1;

        end

    end

end

fil=find(outliers(:,1)==0);

espectro=espectro(fil,:);
```

---

```
end

% valor promedio

mean_espectro=mean(espectro); % valor promedio

% cargado de parametros del PLSR para analisis de queso

N_Ond=xlswrite('Datos del programa.xlsx','Data-Sist','B30');

rango=strcat('A33:A',num2str(33+N_Ond));

betas=xlswrite('Datos del programa.xlsx','Data-Sist',rango);

rango=strcat('C33:C',num2str(33+N_Ond-1));

N_bnd=xlswrite('Datos del programa.xlsx','Data-Sist',rango);

% filtrado de intensidades segun bandas

intensidades= mean_espectro(N_bnd+50);

cc_alm=[ones(1,1),intensidades]*betas;

% coloreado de la imagen

bnd_prom=50;

dsvst=std(espectro_sc(bnd_prom,:));prom=mean(espectro_sc(bnd_prom,:));

LimInf=(prom - dsvst); LimSup=(prom + dsvst);

imagen_col=uint8(imagen_b);

whos espectro_sc

whos imagen_b

for l=1:length(r)

    if (espectro_sc(l,bnd_prom)>LimInf)&&(espectro_sc(l,bnd_prom)<LimSup)

        imagen_col(r(l),c(l))=round(cc_alm*(255/13));

    end

end

end
```

---

```
%mostrando imagen quimiometrica

texto=strcat(texto,' - ',num2str(cc_alm,4),' mg/g');

subplot(2,1,1),imshow(imagen_col)

title(texto,'FontSize',tletra+2)

colormap(hot)

cb1=colorbar;

set(cb1,'YTickLabel',{'0.0','2.6','5.2','7.8','10.4','13.0'})

%ploteando perfil espectral promedio

subplot(2,1,2),

plot(nBandas,mean_espectro');

xlabel('Longitud de onda nm','FontSize',8);

ylabel('Intensidad','FontSize',8);

xlim([0 nBandas(150)])

ylim([10000 20000])

texto=strcat('Long Onda vs Intensidad - ',info.label);

a = get(gca,'XTickLabel');

set(gca,'XTickLabel',a,'FontName','Times','fontsize',tletra)

title(texto,'FontSize',tletra+2)

grid on

%#####Personaliz
zacion de controles para la determinación del marmoleo de carne

%de res

%#####
```

---

```
%Cortado de muestras de carne de res

function btn_meat_cut_Callback(hObject, eventdata, handles)

%declaracion de variables globales

global imagen Puntos centro Puntos_c n_seg Banda info

%limpiar el axes

axes(handles.ax_im);axis off; cla;

%seleccion de la imagen de intensidad de la banda en estudios

im_b=squeeze(imagen(:,:,Banda))./info.reflectance_scale_factor;

im_enuso=im_b;

%mejoramiento de la imagen por ajuste de histograma

im_enuso=imadjust(im_enuso,stretchlim(im_enuso),[]);

%binarizacion, eliminacion de huecos y cerrado de la imagen

Tsh=0.20;

%Tsh=get(handles.sld_tsh,'Value'); %valor de treshold del slider ==valor a poner en

%opciones

im_enuso=im2bw(im_enuso,Tsh);

im_enuso=imfill(~im_enuso,'holes');

im_enuso=imclose(im_enuso,strel('disk',3));

%seleccion del elemento de area mayor

im_enuso=bwlabel(im_enuso);

stats=regionprops(im_enuso,'Area','MajorAxisLength','Centroid'); %determinacion de

area de cada elemento

allArea = [stats.Area];Amax=max(allArea); %calculo area maxima
```

---

```
cc = bwconncomp(im_ensu); %determinacion de componentes
idx = find([stats.Area] == Amax); %busqueda del elemento con area maxima
img_adj = ismember(labelmatrix(cc), idx);%seleccion del elemento con area maxima
centro=stats(idx).Centroid;
img_adj=imfill(img_adj,'holes');%eliminacion de huecos
%determinacion de centroide, Eje mayor y Eje menor
Centroide=regionprops(img_adj,'Centroid');
centro=Centroide.Centroid;
%determinacion de puntos en el borde
im_lim=bwperim(img_adj);
[r c] = find(im_lim==1);
Puntos=zeros(n_seg,3); %puntos de acuerdo al numero de segmentos X, Y, angulo
angulos=(1:1:n_seg);
for j=1:n_seg %numero de segmentos n_seg
    for i=1:length(r)
        round(angRC(r(i),c(i),centro));
        if angulos(1,j)==round(angRC(r(i),c(i),centro));
            Puntos(j,1)=c(i);
            Puntos(j,2)=r(i);
            Puntos(j,3)=angulos(1,j);
        end
    end
end
end
end
%determinacion de puntos a una distancia interior en la carne
```

---

```

Puntos_c=zeros(n_seg,4); %puntos de acuerdo al numero de segmentos X, Y, angulo y
distancia

Puntos_c(:,3)=Puntos(:,3);

%fc=get(handles.sld_fc,'Value');%factor de corte====valor a poner en
%opciones

fc=0.75;

for j=1:n_seg

    d=(Puntos(j,1)-centro(1))^2+(Puntos(j,2)-centro(2))^2;d=d^0.5;

    d=d*fc;Puntos_c(j,4)=d;

    %calculo de distancia de acuerdo al angulo

    if Puntos_c(j,3)<=90; %cuadrante 1

        Puntos_c(j,1)=centro(1)+abs(cosd(Puntos_c(j,3))*d);

        Puntos_c(j,2)=centro(2)+abs(sind(Puntos_c(j,3))*d);

    elseif Puntos_c(j,3)>90 && Puntos_c(j,3)<=180; %cuadrante 2

        Puntos_c(j,1)=centro(1)-abs(cosd(Puntos_c(j,3))*d);

        Puntos_c(j,2)=centro(2)+abs(sind(Puntos_c(j,3))*d);

    elseif Puntos_c(j,3) && Puntos_c(j,3)<=270; %cuadrante 3

        Puntos_c(j,1)=centro(1)-abs(cosd(Puntos_c(j,3))*d);

        Puntos_c(j,2)=centro(2)-abs(sind(Puntos_c(j,3))*d);

    elseif Puntos_c(j,3) && Puntos_c(j,3)<=360; %cuadrante 4

        Puntos_c(j,1)=centro(1)+abs(cosd(Puntos_c(j,3))*d);

        Puntos_c(j,2)=centro(2)-abs(sind(Puntos_c(j,3))*d);

    end

end
end

```

---

```
% mostrando la imagen b y los puntos de perimetro e interiores
cla

hold on

    imshow(im_b)

    plot(Puntos(:,1),Puntos(:,2),'*-r')

    plot(Puntos_c(:,1),Puntos_c(:,2),'*-b')

    plot(centro(1),centro(2),'*g')

hold off

axis xy

axis square

% Segmentacion de la carne

function btn_meat_segm_Callback(hObject, eventdata, handles)

% declaracion de variables globales

global Puntos_c imagen Banda info centro img_capa

% asignacion del foco al axes imagen

axes(handles.ax_im);axis off; cla;

% Seleccion de la imagen de segmentacion segun la banda

img_enuso=squeeze(imagen(:,:,Banda))./info.reflectance_scale_factor;

[r c]=size(img_enuso);

% Reconocimiento de puntos en el interior del elemento de area mayor

img_capa=zeros(r,c,2);

for i=1:r

    for j=1:c
```

---

```
d=(j-centro(1))^2+(i-centro(2))^2;d=d^0.5;
angulo=angRC(i,j,centro);
if round(angulo)==0
    angulo=360;
end
[fil col]=find(Puntos_c(:,3)==round(angulo));
if d<=Puntos_c(fil,4)
    img_capa(i,j,1)=1;
    img_capa(i,j,2)=img_enuso(i,j);
end
end
end
im1=img_capa(:,1);
% mostrar imagen con puntos en el interior
cla
hold on
    imshow(img_capa(:,2))
hold off
axis xy
axis square
display('listo')

%Determinar el marmoleado en funcion de la presencia y distribucion de AGIs
function btn_fatcontent_analysis_Callback(hObject, eventdata, handles)
```

---

```
%declaracion de variables globales
global imagen img_capa im Puntos_c im message X white dark espectro

global val

% %filtrando la imagen

% im=img_capa(:, :, 2);

% %determinar la cantidad de pixeles diferentes de cero
[r c]=find(im~=0);

dim=size(imagen);

%crear matriz de valores para clasificar pixeles
val=zeros(dim(1),dim(2),dim(3));

h=waitbar(0,'Filtrando espectros ...');

% %cargar espectros para clasificar pixeles

load dark;

% dark=mean(mean(dark));

load white;

% white=mean(mean(white));

for i=1:length(r)

    espectro=squeeze(imagen(r(i),c(i),:));

    espectro=100*(espectro-dark)/(white-dark);

    val(r(i), c(i),:)= sgolayfilt(espectro,2,21); %filtrado savorsky golay

    waitbar(i/length(r))

end

close(h)
```

---

```
%Cargando arbol de decisiones

load DT_carne

save val; val

h=waitbar(0,'Aplicando arbol de decisiones...');

%crear matriz de valores para determinar pendientes

X1=(46:1:53);X2=(57:1:76);

evaluacion de espectros y clasificacion \

Ondas=[51:1:126];

whos Ondas

for i=1:length(r)

    minimo= squeeze(val(r(i),c(i),10));

    p=squeeze(val(r(i),c(i),Ondas));

    whos p

    p=p-minimo;

    p=p';

    p1=polyfit(X1,squeeze(val(r(i),c(i),X1)),1);

    p2=polyfit(X2,squeeze(val(r(i),c(i),X2)),1);

    p=cat(2,p,p1(1),p2(1));

    Valor=round(eval(DT_carne,p));

    if Valor==1

        im(r(i),c(i))=1;

    else

        im(r(i),c(i))=0;

    end

end
```

---

```
waitbar(i/length(r))
end
close(h)
imshow(im)
axis xy
axis square
%mostrar imagen clasificada con valores booleanos, previo mejoramiento y
%eliminacion de ruidos
im = medfilt2(im);im=~im;
im = medfilt2(im);im=~im;
se = strel('diamond',3);
im = imdilate(im,se);
hold on
    imshow(im)
    plot(Puntos_c(:,1),Puntos_c(:,2),'*-b')
hold off
axis xy
axis square
%determinar los descriptores
im_enuso=im;
stats=regionprops(im_enuso,'Area');
Areas= cat(1, stats.Area);
Max_a=max(Areas);
cc = bwconncomp(im_enuso);
```

---

```
sltrat=get(handles.sld_sltrat,'Value');
idx = find([stats.Area] >= Max_a*sltrat);
im_enuso = ismember(labelmatrix(cc), idx);
im_enuso=medfilt2(im_enuso, [9 9]);
imshow(im_enuso)
axis xy
axis square
stats=regionprops(im_enuso,'Area','Perimeter','Centroid','MajorAxisLength','MinorAxis
Length','EquivDiameter');
centros = cat(1, stats.Centroid);
Areas=cat(1, stats.Area);
hold on
    plot(centros(:,1), centros(:,2), 'r*', 'MarkerSize', 3)
    plot(Puntos_c(:,1), Puntos_c(:,2), '*-b', 'MarkerSize', 3)
hold off
stad_img=zeros(length(centros), 7);
% 1 =area porcentual total
% 2 =area porcentual relativa
% 3 = vecino mas cercano
% 4 = distancia al vecino mas cercano, distancia normalizada con la distancia maxima
de vecinos
% 5 = redondez (4*pi()*area/p^2)
% 6 = Elongación Eje mayor / eje menor
% 7 = Perimetro / diametro equivalente
```

---

```

Area_t= sum(sum(img_capa(:,1)));
Stad=regionprops(img_capa(:,1),'EquivDiameter');
Dmax=Stad(1).EquivDiameter;
%deterinar los estadisticos para cada AGI en las muestras
for k=1:length(centros)
    stad_img(k,1)=100*Areas(k,1)/Area_t; %area total
    stad_img(k,2)=100*Areas(k,1)/sum(Areas(:,1)); %area individual promedio
    centro=stats(k).Centroid;
    for n=1:length(centros)
        if n~=k
            centrov=stats(n).Centroid; % x, y
            D=(centro(1)-centrov(1))^2+(centro(2)-centrov(2))^2;D=sqrt(D);
            if stad_img(k,4)==0 ||stad_img(k,4)>D
                stad_img(k,4)=D;
                stad_img(k,3)=n;
            end
        end
    end
end
if k==length(centros)
    stad_img(:,4)=stad_img(:,4)/Dmax; %normalizacion con respecto a la distancia
maxima
end
stad_img(k,5)=4*pi*stats(k).Area/(stats(k).Perimeter^2);
stad_img(k,6)=stats(k).MajorAxisLength/stats(k).MinorAxisLength;

```

---

```
    stad_img(k,7)=stats(k).Perimeter/stats(k).EquivDiameter;
end
%Mostrar puntos en analisis
hold on
    for l=1:length(centros)
        centro=stats(l).Centroid;%elemento partida
        centrov=stats(stad_img(l,3)).Centroid;%elemento llegada
        plot([centro(1) centrov(1)],[centro(2) centrov(2)],'*-r')
    end
hold off
axis xy
axis square
stad_img=stad_img(:,[1 2 4 5 6 7]);
%determinar clase para la carne
data_norma=xlsread('Data_programa2.xlsx','Data_normas','B4:H14');
clase=zeros(1,6);X=zeros(1,6);
for k=1:6
    if k==1
        Xi=sum(stad_img(:,k));
        pp=polyfit(data_norma(:,k+1),data_norma(:,1),2);
        clase(1,k)=(polyval(pp,Xi));
    elseif k==2
        Xi=median(stad_img(:,k));
        if (1.54<=Xi) && (Xi<=18)
```

---

```
        clase(1,k) =
(interpl(sort(data_norma(1:6,k+1),'ascend'),sort(data_norma(1:6,1),'descend'),Xi,'linear'
));
    else
        clase(1,k) = NaN;
    end
elseif k==3
    Xi=median(stad_img(:,k));
    if (0.077<=Xi) && (Xi<=0.27)
        clase(1,k) = (interpl(data_norma(1:7,k+1),data_norma(1:7,1),Xi,'linear'));
    else
        clase(1,k) = NaN;
    end
else
    Xi=median(stad_img(:,k));
    pp=polyfit(data_norma(:,k+1),data_norma(:,1),2);
    clase(1,k)=(polyval(pp,Xi));
end
X(1,k)=Xi;
end
%adicionamos los parametros a X
param(1)=get(handles.sld_tsh,'Value');
param(2)=get(handles.sld_fc,'Value') ;
param(3)=get(handles.sld_sgmtsh,'Value');
```

---

```

param(4)=get(handles.sld_sltrat,'Value');
set(handles.txt_clase,'String',round(clase(1,1)));

% mostrando parametros estadisticos de la carne

texto1= strcat('Percent whole area_____ =__', num2str(X(1,1),3));
texto2= strcat('Percent individual area_____ =__', num2str(X(1,2),3));
texto3= strcat('Nearest neighbor distance_____ =__', num2str(X(1,3),3));
texto4= strcat('Roundnes_____ =__', num2str(X(1,4),3));
texto5= strcat('Elongation_____ =__', num2str(X(1,5),3));
texto6= strcat('Perimeter / equiv diameter_____ =__', num2str(X(1,6),3));
Texto=char(texto1,texto2,texto3,texto4,texto5,texto6);
set(handles.txt_stadgrasa,'String',Texto)

%concademamo resultados
X=cat(2,param, X,clase(1,:));
msgbox('End classification stage',message)

%#####%Control
s de uso general a todos los analisis

%#####

%Determinación de espectros en linea de la muestra
function uip_line_ClickedCallback(hObject, eventdata, handles)

%declaracion de variables globales
global img_enuso Xint Yint p tletra

%cargar imagen para la segmentacion

```

---

```
Banda=round(get(handles.sld_lo,'Value'));
%grabar puntos para dimensionar imagen y escala
[Xn,Yn]=ginput(2);
%Plotear la linea de muestreo
hold on
plot(Xn,Yn,'-r')
hold off
%calculando mediante ajuste
p = polyfit (Xn, Yn, 1);
Nunid=40;%X interpolado he colocado 40 unidades
Xint=round(linspace(Xn(1),Xn(2),40));
Yint = round(polyval (p, Xint));
%cargando los valores en una matriz intensidad
Int=zeros(1,length(Xint));
for i=1:length(Xint)
    Int(1,i)= img_enuso(Yint(i),Xint(i),Banda);
end
%graficando en un nuevo figure
figure,
plot(Xint, Int(1,:),'-r')
ylim([0 1.2*max(Int(1,:))])
a = get(gca,'XTickLabel');
set(gca,'XTickLabel',a,'FontName','Times','fontSize',tletra)
title('Reflectance vs X absolute','FontSize', tletra+2)
```

---

```
xlabel('X absolute')
ylabel('Reflectance')
grid on
%legend('Fitted','Location','Best')
axes(handles.ax_im);
%Graba imagenes del axes imagen en carpeta
function btn_save_Callback(hObject, eventdata, handles)
%Declaracion de variables globales
global info message Val Path
folder=strcat(cd, '\imagenes\');
%guardar la imagen RGB
imagen=getimage(handles.ax_rgb);
imagen=imrotate(imagen,180);
texto=strcat(info.label, '-RGB');
name=strcat(folder, texto, '.jpg');
imwrite(imagen, name)
% guardar imagen analizada
imagen=getimage(handles.ax_im);
imagen=imrotate(imagen,180);
texto=strcat(info.label, '-Result');
name=strcat(folder, texto, '.jpg');
imwrite(imagen, name)

%Seleccionar manual de region de interes
```

---

```
function uip_select_ClickedCallback(hObject, eventdata, handles)

%Declaracion de variables globales

global img_enuso nBandas Banda info tletra

%seleccion manual de area de analisis

h = imfreehand; %funcion manual

position = wait(h);%esperar posicion

BW = createMask(h); %crear mascara BW

%determinando valor promedio

[f c]=find(BW==1);

Val=zeros(length(nBandas),length(f));

for i=1:length(f)

    Val(:,i)= sgolayfilt(squeeze(img_enuso(f(i),c(i),:)),2,5);

end

Val_prom=mean(Val');

%determinar valor perimetro

[BW_f BW_c]=find(bwperim(BW,8)==1); %determiando el perimetro

Val=zeros(length(nBandas),length(BW_f)); % Length (f) numero de puntos

for i=1:length(BW_f)

    Val(:,i)= sgolayfilt(squeeze(img_enuso(BW_f(i),BW_c(i),:)),2,5);

end

Val_per=mean(Val');

%determinar y graficar valor centro

figure %creando nuevo figure

stats=regionprops(BW,'Centroid');
```

---

```
centro = round(cat(1, stats.Centroid));

hold on

    plot(centro(1),centro(2),'*g')

hold off

Val_ctr=zeros(length(nBandas),1);

Val_ctr=sgolayfilt(squeeze(img_enuso(centro(2),centro(1),:)),2,5);

%mostrar valor de perimetro, centro y promedio

hold on

    plot(Val_prom,'.b')

    plot(Val_per,'-r')

    plot(Val_ctr,'.g')

hold off

a = get(gca,'XTickLabel');

set(gca,'XTickLabel',a,'FontName','Times','fontSize',tletra)

title('Mean spectra','FontSize', tletra+2)

xlabel('Band');

ylabel('Reflectance');

legend('Perimeter','Mean','Center','Location','Best')

grid on

msgbox('Analysed Region')

%devolviendo foco al ax_im

axes(handles.ax_im);

%Mostrar espectro de un punto
```

---

```
function uip_espectro_ClickedCallback(hObject, eventdata, handles)

%declaracion de variables globales

global img_enuso info tletra

%lectura de la posicion en la imagen, mediante el mouse

[X,Y]=ginput(1);

X=round(X);Y=round(Y);

%rango para determinar el area

rango=(1:1:info.bands);

%carga valor de intensidad de cada pixel

espectro=squeeze(img_enuso (Y,X,:));

espectro_f=sgolayfilt(espectro,2,21); %espectro filtrado

%carga valor en nm de cada onda

ondas=round(sscanf(info.wavelength,'% *c %f'));

ondas=ondas(rango,1);

%graficando espectro

figure;

plot(ondas,espectro(rango,1),'*g',ondas,espectro_f(rango,1),'-r','linewidth',1)

a = get(gca,'XTickLabel');

set(gca,'XTickLabel',a,'FontName','Times','fontSize',tletra)

title('Reflectance vs Wavelength','FontSize', tletra+2)

legend ('Spectra','Corrected spectra','Location','Best')

xlabel('Wavelength (nm)')

ylabel('Intensity')

grid on
```

---

```
axes(handles.ax_im)

%Mostrando imagen de intensidad a longitud Lo

function sld_lo_Callback(hObject, ~, handles)

%declaracion de variables globales

global img_enuso nBandas info Banda

%correccion de imagen por reflectancia

Banda=round(get(hObject,'Value'));

set(handles.txt_lo,'String',num2str(nBandas(Banda)));

set(handles.txt_band,'String',Banda)

%mostrar imagen en uso y el titulo en el axes

axes(handles.ax_im);axis off; cla

if max(max(img_enuso))>250

    imagen=img_enuso(:,:,Banda)./info.reflectance_scale_factor;

else

    imagen=img_enuso(:,:,Banda);

end

%mostrar imagen correguida

imshow(imagen);

axis xy

texto=strcat(info.label,'-at-',num2str(nBandas(Banda)), 'nm');

title(texto)

%llamada al guide entrenamiento

function btn_entr_Callback(~, ~, handles)
```

```
global Muestra
if Muestra(1)==1
    entrenamientoHoja
elseif Muestra(2)==1
    entrenamientoQueso
elseif Muestra(3)==1
    entrenamientoCarne
end
```

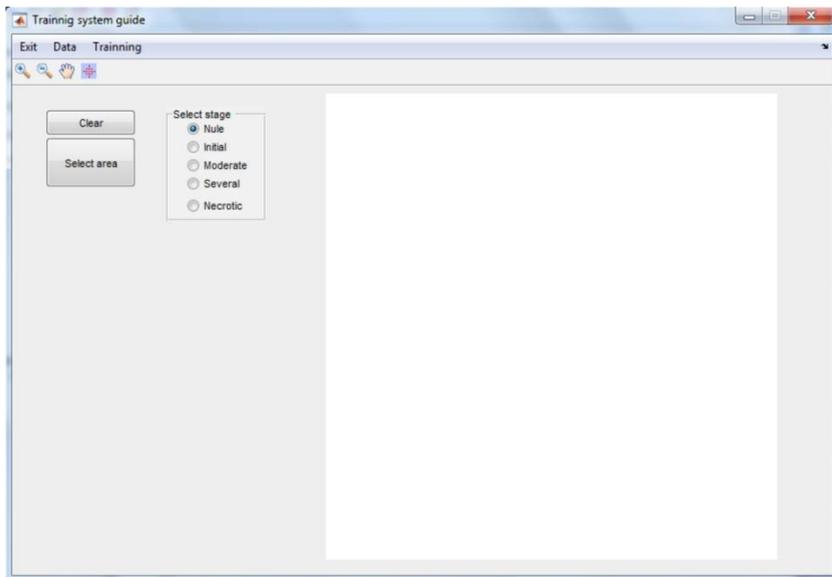


Figura A. 2 Guide entrenamiento Hoja

```
%===== % GUIDE:
entrenamientoHoja.fig / entrenamientoHoja.m
% AUTOR: MSC. ING. WILSON MANUEL CASTRO SILUPU
%=====

%Funciones de preparacion del guide

function varargout = entrenamientoHoja(varargin)

gui_Singleton = 1;

gui_State = struct('gui_Name',    mfilename, ...
                  'gui_Singleton', gui_Singleton, ...
                  'gui_OpeningFcn', @entrenamientoHoja_OpeningFcn, ...
                  'gui_OutputFcn', @entrenamientoHoja_OutputFcn, ...
                  'gui_LayoutFcn', [] , ...
                  'gui_Callback', []);

if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
```

---

```
end

if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end

%Apertura del Guide
function entrenamientoHoja_OpeningFcn(hObject, eventdata, handles, varargin)
% Declaracion de variables globales
global imagenRGB Banda imagen info img
%Preparar axes
axes(handles.axes_ondas); axis off; cla;
axes(handles.axes_imagen); axis off; cla;
% Mostrar imagenes
if Banda == 0
    imshow(imagenRGB)
else
    img=squeeze(imagen(:,:,Banda));
    img=img./info.reflectance_scale_factor;
    imshow(img)
end
axis xy
```

---

```
% Actualizar salidas y guides
handles.output = hObject;

guidata(hObject, handles);

% Funcion de salidas del guide
function varargout = entrenamientoHoja_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;

% Cierra el guide y muestra el guide Hyper
function mnu_exit_Callback(hObject, eventdata, handles)
close(entrenamientoHoja)

% Limpieza de axes - elimina ROIs
function cmd_clear_Callback(hObject, eventdata, handles)

% Declaracion de variables globales
global img

% Mostrar imagen
axes(handles.axes_imagen); cla; axis off;

imshow(img)

axis xy

% Obtencion de espectros puntuales
function uip_espectro_ClickedCallback(hObject, eventdata, handles)

% Declaracion de variables globales
```

---

```
global imagen nBandas

% Analisis de espectros puntuales

[X,Y]=ginput(1); %adquisicion de punto a leer con puntero del mouse

X=round(X);Y=round(Y); %redondeo de la posicion

espectro=squeeze(imagen(Y,X,:)); %extraccion de intensidades en la imagen para X,Y

espectro_f=sgolayfilt(espectro,2,21); %espectro filtrado por Savorsky Golay, orden 2

% Grafico de intensidades

rango=(26:1:126);%rango para determinar las intensidades (200 - 1000 nm)

ondas=nBandas(rango,1); %las ondas a usar dependen del rango

% Graficando espectro

figure; plot(ondas,espectro(rango,1),'*g',ondas,espectro_f(rango,1),'-r',
'linewidth',1)%mostrar espectros

tletra=10;

title('Pixel intensity vs Wavelength','FontSize', tletra)

legend ('Spectra','Corrected spectra','Location','southoutside','Orientation','Horizontal')

xlabel('Wavelength (nm)','FontSize', tletra);

ylabel('Intensity','FontSize', tletra)

ylim([0 14000])

grid on

%Regresa foco al al axes im

axes(handles.axes_imagen);

%Obtencion de espectros promedios de una ROI

function cmd_selarea_Callback(hObject, eventdata, handles)
```

---

```
%Declaracion de variables globales
global imagen Val message nBandas

%Seleccion de ROI manualmente

h = imfreehand;

position = wait(h);

BW = createMask(h);

setColor(h,'r')

%Determinando valor promedio

[f c]=find(BW==1);

Val=zeros(150,length(f));

for i=1:length(f)

    Val(:,i)= sgolayfilt(squeeze(imagen(f(i),c(i),:)),2,21);

end

Val_prom=mean(Val');

%Determinando valor perimetro

[BW_f BW_c]=find(bwperim(BW,8)==1); %determinando el perimetro

Val=zeros(length(nBandas),length(BW_f));%[m n], 150 = numero de ondas , Length (f)

numero de puntos

for i=1:length(BW_f)

    Val(:,i)= sgolayfilt(squeeze(imagen(BW_f(i),BW_c(i),:)),2,21);

end

Val_per=mean(Val');

%Determinando valor centro

stats=regionprops(BW,'Centroid');
```

---

```
centro = round(cat(1, stats.Centroid));

hold on

plot(centro(1),centro(2),'g')

hold off

Val_ctr=zeros(150,1);

Val_ctr=sgolayfilt(squeeze(imagen(centro(2),centro(1),:)),2,21);

%Graficando valores promedio, centro y perimetro de espectros de la ROI

axes(handles.axes_ondas);cla; axis 'on';

hold on

plot(Val_prom,'.b')

plot(Val_per,'.-r')

plot(Val_ctr,'.-g')

hold off

grid on

xlabel('Band');

ylabel('Reflectance');

axis([20 100 0 14000])

legend('Perimetro','Promedio','Centro','Location','Best')

msgbox('Analysed Region',message)

%Grabado de datos en libro Data_train

function mnu_svdata_Callback(hObject, eventdata, handles)

%Declaracion de variables globales

global Val message nBandas
```

---

```
% Seleccion de clase

if get(handles.rdb_nule,'Value')==1

    tipo=1;

elseif get(handles.rdb_initial,'Value')==1

    tipo=2;

elseif get(handles.rdb_moderate,'Value')==1

    tipo=3;

elseif get(handles.rdb_several,'Value')==1

    tipo=4;

elseif get(handles.rdb_necrotic,'Value')==1

    tipo=5;

end

%opcion de grabado en la hoja excel

h=questdlg('Do you want to save the information',message);

if strcmp(h,'Yes')==1

dim=size(Val);

Lxcl='Data_train_hoja.xlsx';

tipos=ones(dim(2),1);tipos=tipos*tipo;

data=xlsread(Lxcl,'Data');

    if isempty(data)==1 %matriz vacia

        X=cat(2,Val',tipos);

        % el codigo 1010101010 indica codificacion de clase

        cabecera=nBandas';cabecera=cat(2,cabecera,1010101010);

        X=cat(1,cabecera,X);
```

---

```
    xlswrite(Lxcl,X,'Data','A1');%datos
else %matriz con datos, colocar cabecera
    X=cat(2,Val',tipos);
    X=cat(1,data,X);
    xlswrite(Lxcl,X,'Data','A1');%datos
end
end
[dim_f dim_c]=size(X);
msgbox(strcat(num2str(dim(2)),'- values added','--',num2str(dim_f-1),'-Total
register'),message);

% Limpiar hoja Data
function mnu_cldata_Callback(hObject, eventdata, handles)
global message
%Llamada a la funcion de borrado de hoja en el libro de excel
Borrar_hoja('Data_train_hoja', 'Data')
msgbox('Worksheet was cleaned',message);

%Limpiado de hojas
function Borrar_hoja(libro, hoja)
Excel = actxserver('Excel.Application');
Workbook = Excel.Workbooks.Open(strcat(pwd,'\',libro,'.xlsx'));
set(Excel, 'Visible', 0);set(Excel,'DisplayAlerts',0);
curSheet = Excel.ActiveWorkbook.Sheets;
```

---

```
Sheets = Excel.Worksheets;
Rsheet = get(Sheets, 'Item', hoja);
invoke(Rsheet, 'Activate');
Rsheet.Cells.Clear

% grabar y cerrar objeto
Workbook.Save;
Workbook.Close(false);
Excel.Quit;
delete(Excel);

%Entrenamiento de sistema inteligente
function mnu_training_Callback(hObject, eventdata, handles)
%Declaracion de variables globales
global message metodo
%Eliminacion de Outlyers
%Extraccion de datos de la hoja excel
Lxcl='Data_train_hoja.xlsx';
data=xlsread(Lxcl,'Data');
dim=size(data);
%Filtado savorsky golay
intensidad=sgolayfilt(data(2:dim(1),1:dim(2)-1),2,21);
%Concatenado de matrices luego del filtrado
x=cat(2,intensidad,data(2:dim(1),151));
```

---

```
data=cat(1,data(1,:),x);
n=0;
for i=1:5 %Extraer datos por cada clase
for j=20:100 %Recorer un rango de longitudes de onda para eliminar outlyers
    f=find(data(:,151)==i);
    media=mean(data(f,j));
    Dsv=2*std(data(f,j));
    for k=1:length(f)
        if data(f(k),j)< media-Dsv || data(f(k),j)> media+Dsv
            n=n+1;
            data(f(k),151)=0;
        end
    end
    f=find(data(:,151)>0);
    data=data(f,:);
end
f=find(data(:,151)>0);
data=data(f,:);
end

%Creacion de clasificador inteligente
[f c]=size(data);
indices=zeros(f-1,6);
clases=zeros(f-1,1);
```

---

```
for i=2:f
    %Suavizado filtro savorsky golay
    intensidades=sgolayfilt(data(i,:),2,21);
    %Normalizando espectro al valor minimo
    minimo=min(intensidades(1:40));
    intensidades=intensidades-minimo;
    indices(i-1,1)=minimo;
    indices(i-1,2)=max(intensidades(20:55));
    indices(i-1,3)=min(intensidades(45:75));
    %Obtencion de pendientes
    x=[75:1:83]; y=intensidades(x); x=(x-1).*8;
    p=polyfit(x,y,1);
    indices(i-1,4)=p(1);
    x=[88:1:115]; y=intensidades(x); x=(x-1).*8;
    p=polyfit(x,y,1);
    indices(i-1,5)=p(1);
    %Relacion entre pendientes
    indices(i-1,6)=indices(i-1,4)/indices(i-1,5);
end
clases(:,1)=data(2:f,151); % 150 bandas y la de clasificacion
%Llamada a la funcion de borrado de hoja resultados
Borrar_hoja('Data_train_hoja','Calculos')
%grabado en hoja calculos de indices y clases
xlswrite(Lxcl,cats(2,indices,clases),'Calculos','A1');%datos
```

---

```
%Analizando con sistemas inteligentes

data=xlsread(Lxcl,'Calculos');

p=data(:,1:6);t=data(:,7);

%Seleccionando sistema a usar

if metodo(1)==1 %redes neuronales

    tc = ind2vec(t');

    RNA_leave = newpnn(p',tc);

    clase_r = sim(RNA_leave,p'); clase_r = vec2ind(clase_r);

    clase_r=clase_r';

    save RNA_leave RNA_leave

elseif metodo(2)==1 % SVM

    SVM_leave = fitcecoc(p,t');

    clase_r = predict(SVM_leave,p);

    save SVM_leave SVM_leave

elseif metodo(3)==1 % arbol de decisiones

    DT_leave= classregtree(p,t);

    save DT_leave DT_leave

    clase_r=round(eval(DT_leave,p));

end

%determiando error de calculo

error=[1:1:length(t)];error(:)=1;

for i=1:length(t)

    if t(i)==clase_r(i)

        error(i)=0;
```

```
else
    error(i)=1;
end
end
msgbox(strcat('Error = ', num2str(100*sum(error)/length(error),'% 10.5e\n'),'
%'),message);
```

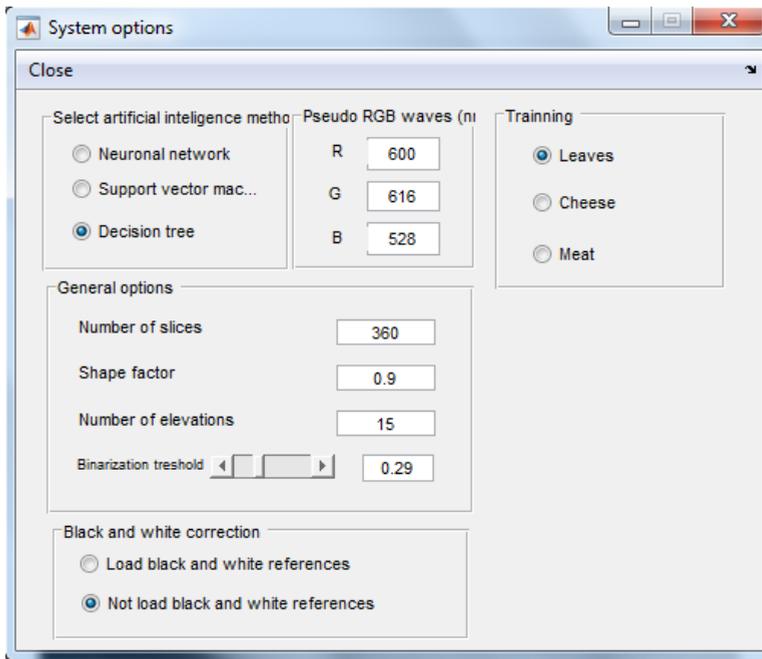


Figura A. 3 Guide entrenamiento Opciones

```
%=====
%=====
% GUIDE: OPCIONES DEL SISTEMA
% AUTOR: MSC. ING. WILSON MANUEL CASTRO SILUPU
%=====
%=====
```

```
function varargout = opciones(varargin)

gui_Singleton = 1;

gui_State = struct('gui_Name',    mfilename, ...
                  'gui_Singleton', gui_Singleton, ...
                  'gui_OpeningFcn', @opciones_OpeningFcn, ...
                  'gui_OutputFcn', @opciones_OutputFcn, ...
                  'gui_LayoutFcn', [], ...
                  'gui_Callback', []);
```

---

```
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end

function opciones_OpeningFcn(hObject, eventdata, handles, varargin)
%declaracion de variables globales
global opcHyper1 RGB_index Muestra
%cargar variables
load opcHyper1
%carga en los controles
set(handles.opt_RNA,'Value',opcHyper1(1));
set(handles.opt_SVM,'Value',opcHyper1(2));
set(handles.opt_DT,'Value',opcHyper1(3));
set(handles.txt_nc,'String',num2str(opcHyper1(4)));
set(handles.txt_ff,'String',num2str(opcHyper1(5)));
set(handles.txt_ne,'String',num2str(opcHyper1(6)));
set(handles.txt_tsh,'String',num2str(opcHyper1(7)));
set(handles.sld_tsh,'Value',opcHyper1(7));
```

---

```
set(handles.rdb_bwcorrYES,'Value',opcHyper1(8));
set(handles.rdb_bwcorrNO,'Value',opcHyper1(9));

%cargar variables RGB

load RGB_index

%cargar en los controles

set(handles.txt_R,'String',num2str(RGB_index(1)));
set(handles.txt_G,'String',num2str(RGB_index(2)));
set(handles.txt_B,'String',num2str(RGB_index(3)));

%cargar variable muestra

load Muestra

%cargar en los controles

set(handles.opt_leaves,'Value',Muestra(1));
set(handles.opt_cheese,'Value',Muestra(2));
set(handles.opt_meat,'Value',Muestra(3));

handles.output = hObject;

%actualizar estructuras

Update handles structure

guidata(hObject, handles);

function varargout = opciones_OutputFcn(hObject, eventdata, handles)

varargout{1} = handles.output;

function mn_cerrar_Callback(hObject, eventdata, handles)

%declaracion de variables globales
```

---

```
global opcHyper1 RGB_index file Muestra

%comparar si se han modificado los valores

%crear vector data con informacion de ambas variables

data=cat(1,opcHyper1',RGB_index,Muestra);

%carga los datos de los controles

dataN(1)=double(get(handles.opt_RNA,'value'));
dataN(2)=double(get(handles.opt_SVM,'value'));
dataN(3)=double(get(handles.opt_DT,'value'));
dataN(4)=str2double(get(handles.txt_nc,'string'));
dataN(5)=str2double(get(handles.txt_ff,'string'));
dataN(6)=str2double(get(handles.txt_ne,'string'));
dataN(7)=str2double(get(handles.txt_tsh,'string'));
dataN(8)=double(get(handles.rdb_bwcorrYES,'value'));
dataN(9)=double(get(handles.rdb_bwcorrNO,'value'));
dataN(10)=str2double(get(handles.txt_R,'String'));
dataN(11)=str2double(get(handles.txt_G,'String'));
dataN(12)=str2double(get(handles.txt_B,'String'));
dataN(13)=double(get(handles.opt_leaves,'value'));
dataN(14)=double(get(handles.opt_cheese,'value'));
dataN(15)=double(get(handles.opt_meat,'value'));

%compara con los datos precargados y asignan 1 a la variable opcion si hay

%cambios

for i=1:15

    if data(i)~= dataN(i)
```

---

```
    opcion(i)=1;

else

    opcion(i)=0;

end

end

opcion=sum(opcion);

%Guardar los cambios en las variables

if opcion >=1

    opcHyper1 =dataN(1:9);

    RGB_index=dataN(10:12);

    Muestra=dataN(13:15);

    %cambiar datos en la hoja

    xlswrite(file,dataN(1),'Data-Sist', 'B1');

    xlswrite(file,dataN(2),'Data-Sist', 'B2');

    xlswrite(file,dataN(3),'Data-Sist', 'B3');

    xlswrite(file,dataN(4),'Data-Sist', 'B4');

    xlswrite(file,dataN(5),'Data-Sist', 'B5');

    xlswrite(file,dataN(6),'Data-Sist', 'B6');

    xlswrite(file,dataN(7),'Data-Sist', 'B16');

    xlswrite(file,dataN(8),'Data-Sist', 'B19');

    xlswrite(file,dataN(10),'Data-Sist', 'B11');

    xlswrite(file,dataN(11),'Data-Sist', 'B12');

    xlswrite(file,dataN(12),'Data-Sist', 'B13');

    xlswrite(file,dataN(13),'Data-Sist', 'F2');
```

```
xlswrite(file,dataN(14),'Data-Sist', 'F3');  
xlswrite(file,dataN(15),'Data-Sist', 'F4');  
  
end  
  
save opcHyper1 opcHyper1  
save RGB_index RGB_index  
  
save Muestra Muestra  
  
%recargar variables  
  
Ini_Var  
  
% Actualizando handles  
guidata(hObject, handles)  
  
%Cierra el guide opciones  
close (opciones);  
  
  
function sld_tsh_Callback(hObject, eventdata, handles)  
  
Tsh=get(hObject,'Value');  
  
set(handles.txt_tsh,'String',num2str(Tsh));
```