



Institución Universitaria

Detección de enfermedades en plantas de crisantemo, por medio de visión artificial aplicada a imágenes multiespectrales

Carlos Andrés Sánchez Ríos

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2020

Detección de enfermedades en plantas de crisantemo, por medio de visión artificial aplicada a imágenes multiespectrales

Carlos Andrés Sánchez Ríos

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Automatización y Control Industrial

Director (a):

Ph.D. Jorge Alexis Herrera Ramírez

Línea de Investigación:

Visión Artificial y Fotónica

Grupo de Investigación:

Automática Electrónica y Ciencias Computacionales

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2020

(Dedicatoria o lema)

Lo que actualmente llamamos mundo es el resultado de múltiples errores y fantasías, que han ido surgiendo paulatinamente en la evolución del conjunto de los seres organizados, que se entremezclaron al crecer, llegando a nosotros por herencia como un tesoro acumulado a lo largo del pasado.

Federico Nietzsche

Agradecimientos

Quiero presentar un sincero agradecimiento a las siguientes personas sin las cuales claramente este trabajo no hubiese podido llegar a buen término.

En primer lugar, quiero agradecer a mi director Jorge Herrera por su tiempo, orientación, dedicación, ayuda y acompañamiento tanto en mi desarrollo académico como personal e igualmente por su gran paciencia conmigo.

En segunda instancia a Andrés Cardona, sin su acompañamiento este proceso académico no hubiera sido posible, gracias a su disponibilidad para impartirme el valioso conocimiento que desarrolló durante años en la industria floricultora fue posible el desarrollo de este trabajo.

También quiero agradecer inmensamente a mis amigos y compañeros Sebastián, Jonathan, Juan Pablo y Steven, quiénes de una u otra manera me acompañaron en este proceso, ya fuera tendiéndome la mano cuando requería de ayuda, con su presencia para disfrutar de momentos de gozo y risa, o su compañía aún desde la lejanía. Igualmente, a mi mentor Diego Hincapié quién me introdujo al campo de la investigación desde el pregrado y aún se preocupa por mi desarrollo profesional y personal.

A Lorena y Karla, por las noches de tertulia y risas que me ayudaron a liberar un poco el estrés, y como no agradecer a Freddy por su disponibilidad para escucharme o compartir una cerveza en silencio, brindándome valiosas palabras de apoyo que nunca podría imaginarse el peso que han tenido. A mi hermano Mauricio igualmente por siempre preocuparse por mi aún con los pocos momentos que en los últimos años hemos compartido.

Finalmente, a mis padres y mi abuelo, quiénes me han brindado su apoyo y comprensión durante estos años trabajo, sin dejar de lado a mi mascota Lilith que me ha acompañado en las arduas madrugadas de trabajo.

Resumen

El sector floricultor se presenta como un gran mercado tanto a nivel nacional como internacional, de tal manera que Colombia se encuentra actualmente afianzado como el primer exportador de flores a los Estados Unidos, donde cerca del 80% de las flores importadas por este país son colombianas. Dado esto, para garantizar la estabilidad y desarrollo de esta industria, se hace necesario contar con sistemas de control fitosanitarios rigurosos. El control de estos problemas es de importancia en ámbitos de fitosanidad internacional ya sea para evitar la dispersión de posibles problemas a otras especies de fauna y flora, o para cumplir con estándares de calidad. Por esto, dada la falta de estudios locales y la necesidad actual de incluir nuevas tecnologías en los procesos de la industria floricultora Antioqueña, es que en este trabajo se realiza la optimización de un sistema de visión artificial para la identificación de plagas y/o enfermedades presentes en hojas de crisantemo. Para ello se optimizaron parámetros como los tiempos de adquisición de la cámara, control del ruido y corrección de uniformidad de un equipo de adquisición de imágenes multiespectrales en laboratorio, con una selección de canales espectrales dada por una identificación previa de las zonas de interés fitosanitario para el crisantemo. Para su identificación, se analizaron las firmas espectrales de muestras de hojas de crisantemo obtenidas en cultivos del oriente antioqueño. Estas muestras presentaron síntomas de siguientes enfermedades representativas: trips, Virus del marchitamiento moteado del tomate (*TSWV: Tomato Spotted Wilt Virus*) y ácaros (*Tetranychus sp*). Una vez calibrado y optimizado el sistema de captura para este tipo de muestras, se generaron imágenes multiespectrales de hojas de crisantemo con síntomas de las enfermedades anteriormente mencionadas. Finalmente, se desarrolló una metodología para la identificación de muestras sanas o con las enfermedades mencionadas, utilizando herramientas de procesamiento de imágenes, análisis multiespectral y aprendizaje de máquina.

Palabras clave: Imágenes multiespectrales, espectroscopía, fitosanidad, detección de enfermedades, procesamiento de imágenes.

Abstract

The floriculture sector is presented as a large market both nationally and internationally, in such a way that Colombia is currently established as the first exporter of flowers to the United States, where about 80% of the flowers imported by this country from Colombia. Given this, to guarantee the stability and development of this industry, it is necessary to have rigorous phytosanitary control systems. The control of these problems is of importance in international phytosanitary areas, either to avoid the spread of possible affections to other species of fauna and flora or to comply with quality standards. For this reason, given the lack of local studies and the current need to include new technologies in the processes of the Antioquia flower industry, this work optimizes an artificial vision system for the identification of pests and/or diseases in chrysanthemum leaves. A multispectral image acquisition equipment was optimized by previously identifying phytosanitary areas of interest. Then, chrysanthemum leaf samples collected from crops on eastern Antioquia were measured, and their spectral signatures were analysed. These samples showed symptoms of the following representative diseases: thrips, Tomato Spotted Wilt Virus (TSWV: Tomato Spotted Wilt Virus), and mites (*Tetranychus* sp). Once the capture system had been calibrated and optimized for this type of sample, multispectral images of chrysanthemum leaves with symptoms of the diseases were generated. Finally, a methodology was developed for the identification of healthy leaves or those with the mentioned diseases, using image processing tools, multispectral analysis, and machine learning.

Keywords: Multispectral imaging, spectroscopy, plant health, disease detection, image processing.

Contenido

Resumen	IX
Lista de figuras	XIII
Lista de tablas	XVI
Lista de Símbolos y abreviaturas	XVII
Introducción	19
1. Marco Teórico y Estado del Arte	24
1.1 Espectro electromagnético	25
1.2 Sistemas espectrométricos	26
1.3 Sistemas de visión artificial	28
1.3.1 Formación de la imagen	29
1.3.2 Imágenes en el rango visible	31
1.3.3 Imágenes multiespectrales e hiperespectrales	32
2. Determinación de problemas fitosanitarios susceptibles de estudio	37
2.1 Recolección y transporte de material vegetal	39
2.2 Adquisición de firmas espectrales	42
2.2.1 Protocolo de medición	43
2.2.2 Lectura de datos espectrales	45
2.2.3 Normalización de los datos	46
2.3 Firmas espectrales	47
3. Optimización de un prototipo de laboratorio para la captura de imágenes espectrales	51
3.1 Caracterización del sistema de iluminación LED	53
3.1.1 Protocolo de medición	53
3.1.2 Lectura de datos espectrales para los LEDs	53
3.1.3 Procesamiento y análisis de los datos	54
3.1.4 Evaluación de la estabilidad de la emisión de los LEDs	55
3.1.5 Caracterización del sistema de iluminación LED.....	55
3.2 Configuración y calibración del sistema de adquisición	57
3.2.1 Configuración del sistema de adquisición (cámara)	59
4. Metodología para la detección de enfermedades	65
4.1 Procedimiento para la generación de imágenes de reflectancia	65
4.2 Generación de imágenes de reflectancia	67
4.3 Identificación de enfermedades	70
4.3.1 Ácaro	71
4.3.2 Virus	72
4.3.3 Trips	74
5. Resultados de la evaluación de técnicas de clasificación	75
5.1 Clasificación de Virus	76
5.1.1 Segmentación semántica	76

5.1.2	Métodos clásicos (ANN y SVM)	81
5.1	Clasificación de Trips	83
6.	Conclusiones y recomendaciones.....	90
6.1	Conclusiones.....	90
6.2	Recomendaciones.....	91

Lista de figuras

	Pág.
Figura 1-1: Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética (figura tomada de Dyring, 1973).	25
Figura 1-2: Clasificación del espectro electromagnético (figura tomada de Estudios & Centro, 2017).	26
Figura 1-3: Medición de reflectancia total relativa (figura adaptada de Shimadzu, 2019). 27	27
Figura 1-4: Proceso de captura de imágenes donde se muestran los diversos pasos típicos de post-procesamiento digital (imagen adaptada de Szeliski, 2010).	30
Figura 1-5: Representación computacional de una imagen (imagen tomada de Media Production Lab, 2019).	30
Figura 1-6: Representación matricial de una imagen RGB (figura tomada de Matlab, 2019). 31	31
Figura 1-7: Imagen espectral: a) representada como respuesta espectral, b) como un arreglo tridimensional (x, y, λ) (figura adaptada de Sowmya et al., 2019).	33
Figura 2-1: Disposición de parcelas pertenecientes a cultivos de flor nacional. a) Invernadero ubicado en La Ceja, Antioquia, b) Invernadero ubicado en el Carmen de Viboral, Antioquia.	37
Figura 2-2: Flor de crisantemo. a) Tipo pompón, b) Tipo araña.	38
Figura 2-3: Plantación de diferentes variedades de flor de crisantemo en sus inicios de la etapa de floración.	39
Figura 2-4: Procedimiento de reconocimiento y recolección de material vegetal.	40
Figura 2-5: Almacenamiento y transporte de material vegetal. a) Empacado y almacenamiento de muestras recolectadas; b) Método de transporte de transporte para el material vegetal seleccionado.	41
Figura 2-6: Captura de hojas de crisantemo en campo y en laboratorio. a) Hoja de crisantemo en campo antes de ser empacada; b) Hoja de crisantemo en el laboratorio después de haber sido transportada.	41
Figura 2-7: Equipos medición de espectros. a) Espectrofotómetro Yokogawa AQ6373; b) Fibra óptica <i>Ocean optics</i> QR200-7-UV-VIS; c) Fuente laser Energetiq TM – EQ-99X LDLS (Anexo B).	43
Figura 2-8: Disposiciones evaluadas en la posición de la fibra óptica.	44
Figura 2-9: Disposición de los equipos de laboratorio y muestra para la medición de firmas espectrales.	46
Figura 2-10: Material de referencia.	47
Figura 2-11: Respuesta espectral de hojas de crisantemo sanas y con presencia de Virus del marchitamiento moteado del tomate.	48
Figura 2-12: Respuesta espectral de hojas de crisantemo sanas y con presencia de ácaros. 49	49
Figura 2-13: Respuesta espectral de hojas de crisantemo sanas y con presencia de trips. 49	49

Figura 2-14:	Respuesta espectral de hojas de crisantemo sanas, con presencia de ácaros, Virus del marchitamiento moteado del tomate y trips.	50
Figura 3-1:	Ejemplo de panel de iluminación espectral (Gómez Granda et al., 2018)..	52
Figura 3-2:	Procedimiento de medición espectral de LEDs.	54
Figura 3-3:	Disposición del montaje para medición de estabilidad del sistema de iluminación.	55
Figura 3-4:	Comportamiento espectral de cada uno de los LEDs que conforman el sistema de iluminación.	56
Figura 3-5:	Comparativa de estabilidad de emisión del sistema de iluminación.....	57
Figura 3-6:	Equipo de captura. a) cámara Basler acA2040 - 55um (ver Anexo D), b) lente Pentax.	58
Figura 3-7:	Montaje de cámara y sistema de iluminación.	58
Figura 3-8:	Montaje completo para la captura de imágenes multiespectrales en hojas de crisantemo	59
Figura 3-9:	Flujo de operación de la interfaz.....	60
Figura 3-10:	Panel inicial en la interfaz de control del sistema de captura espectral. .	61
Figura 3-11:	Panel de calibración de exposición.....	62
Figura 3-12:	Ventana emergente para la visualización del histograma en el proceso de calibración.	62
Figura 3-13:	Panel de modo manual para la previsualización de la imagen capturada por la cámara.	63
Figura 3-14:	Panel de modo automático para la captura de imágenes.....	64
Figura 4-1:	Procedimiento para la generación de imágenes de reflectancia.	66
Figura 4-2:	Interfaz gráfica para la generación de imágenes de reflectancia a partir de imágenes RAW.	68
Figura 4-3:	Imágenes de reflectancia para una hoja de crisantemo iluminada bajo 11 diferentes longitudes de onda.....	69
Figura 4-4:	Hoja de crisantemo. a) imagen de reflectancia original, b) imagen procesada para la eliminación del fondo y sombras generadas en el contorno la hoja. .	70
Figura 4-5:	Hoja de crisantemo con presencia de ácaro. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.....	72
Figura 4-6:	Hoja de crisantemo con presencia de virus. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.....	73
Figura 4-7:	Identificación de tejido necroso en una imagen espectral correspondiente a los 850 nm.	73
Figura 4-8:	Hoja de crisantemo con presencia de trips. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.....	74
Figura 5-1:	Modelo de la red HybridSN propuesto por (Roy et al., 2020).....	77
Figura 5-2:	Imagen multiespectral de entrenamiento. a) reconstrucción RGB, b) imagen con cada píxel etiquetado.....	78
Figura 5-3:	Sección de hoja con presencia de Virus utilizada en el proceso de validación. a) reconstrucción RGB, b) representación RGB de las predicciones para cada píxel.	80

Figura 5-4: Hoja de crisantemo con presencia de Virus. a) predicción realizada por el modelo de ANN, b) reconstrucción RGB de la hoja.	83
Figura 5-5: Procedimiento de extracción de características tanto de tejido vegetal sano como con presencia de Trips.....	84
Figura 5-6: Hoja de crisantemo con presencia de Trips. a) hoja previa a predicción, b) resultado de predicción sobre el tejido vegetal.	88

Lista de tablas

	Pág.
Tabla 2-1: Configuraciones para los parámetros de medición del espectrofotómetro.	43
Tabla 2-2: Resultados de pruebas calibración para el equipo de sensado y la disposición de la fibra óptica.....	45
Tabla 2-3: Protocolo de calibración para la medición espectral con el analizador de espectros ópticos Yokogawa AQ6373.	45
Tabla 3-1: Longitudes de onda disponibles en el sistema de iluminación.....	52
Tabla 3-2: Configuración definida para la medición de las firmas espectrales correspondientes a cada led en el sistema de iluminación.	53
Tabla 5-1: Información de recolección de muestras de tejido vegetal con presencia de virus y trips.	75
Tabla 5-2: Reporte de clasificación para predicciones en el proceso de validación....	80
Tabla 5-3: Resultados de entrenamiento con validación cruzada para ANN.	82
Tabla 5-4: Resultados de entrenamiento con validación cruzada para SVM.	82
Tabla 5-5: Resultados de entrenamiento para las 12 bases de datos de textura evaluadas con ANN.....	86
Tabla 5-6: Resultados de entrenamiento para las 12 bases de datos de textura evaluadas con SVM.	87

Lista de Símbolos y abreviaturas

Símbolos con letras latinas

Símbolo	Término	Unidad SI	Definición
A	Área	m^2	$\iint dx dy$
λ	Longitud de onda	m	$\lambda = v/f$
L	Longitud	m	DF
T	Temperatura	K	DF
t	tiempo	s	DF
W	Potencia	$\frac{kg \cdot m^2}{s^3}$	$\frac{J}{s}$

Símbolos con letras griegas

Símbolo	Término	Unidad SI	Definición
θ	Ángulo de inclinación	1	Figura 4-1

Abreviaturas

Abreviatura	Término
<i>ANSPE</i>	Agencia Nacional para la Superación de la Pobreza Extrema
<i>ANOVA</i>	Análisis de varianza
<i>bh-MB</i>	bosque húmedo Montano Bajo
<i>CCD</i>	Charge-Coupled Device
<i>CSS</i>	Escalas de Curvaturas
<i>CSV</i>	Coma Separated Values
<i>E</i>	Campo eléctrico
<i>EM</i>	Energía electromagnética
<i>FPS</i>	Frames per second
<i>GPS</i>	Global Positioning System

Abreviatura	Término
<i>ICA</i>	Instituto Colombiano Agropecuario
<i>ITM</i>	Instituto Tecnológico Metropolitano
<i>LDA</i>	Análisis Lineal Discriminante
<i>LED</i>	Light-Emitting Diode
<i>LSB</i>	Less Significant Byte
<i>MSB</i>	Most Significant Byte
<i>QDA</i>	Análisis Cuadrático Discriminante
<i>PCA</i>	Análisis de componentes principales
<i>PNG</i>	Portable Network Graphics
<i>PPR</i>	Relación de Pigmento en la Planta
<i>PWM</i>	Pulse-With Modulation
<i>RGB</i>	Red-Green-Blue
<i>SDI</i>	Índice de enfermedad espectral
<i>SVM</i>	Máquina de Soporte Vectorial
<i>USB</i>	Universal Serial Bus
<i>TIFF</i>	Tagged Image File Format
<i>TSWV</i>	Virus del marchitamiento moteado del tomate

Introducción

Actualmente, Colombia se encuentra considerado como un país megadiverso al poseer una gran variedad de ecosistemas (costeros, marinos, montaña, forestales, etc.) (Bettioli, W.; Rivera, M.; Mondino, P.; Montealegre, J.; Colmenárez, 2014). Esta característica le brinda al país una gran ventaja en el aprovechamiento de dichos recursos en la industria agraria. Así, en sus cincuenta años de existencia, la industria floricultora ha generado resultados significativos en diferentes zonas del país, un ejemplo de esto es la alianza suscrita con la Agencia Nacional para la Superación de la Pobreza Extrema (ANSPE) en 2014. En esta alianza, el trabajo de Asocolflores tuvo repercusiones en la generación de ingresos y capacidades en el departamento de Cundinamarca, alcanzándose una concentración del 70% de la producción nacional de flores (Asocolflores, 2015). En la actualidad, se cuenta en promedio con más de 130 mil personas vinculadas a la producción floricultora, presentando el 25% del empleo rural femenino en el país. Estas cifras no solo impactan al sector económico e industrial, también se afecta de manera directa el sector social, brindando beneficios a cerca de 30.000 familias colombianas en temas de mejoramiento y adquisición de vivienda (Asocolflores, 2015).

De esta manera, Colombia se presenta como un gran actor de mercado a nivel internacional en la industria floricultora, como un ejemplo en fechas como San Valentín alrededor de 660 millones de flores son exportadas, siendo un 26.51% procedente del Oriente antioqueño despachado a mercados en Estado Unidos, Inglaterra y Japón. Según (El Colombiano, 2020) “en 2019 la exportación de flores de Antioquia sumó cerca de 271 millones de dólares y 68.000 toneladas, representando respectivamente cerca de 18 % y 26 % de la exportación”.

Para garantizar la estabilidad y desarrollo de la industria floricultora es necesario contar con sistemas de control fitosanitarios rigurosos, debido al gran efecto que tienen las plagas o enfermedades sobre la producción de un cultivo en ámbitos de fitosanidad internacional, tanto para evitar posibles problemas en la fauna y flora como para cumplir con estándares de calidad (Cut Flowers and Greenery Import Manual Cut Flowers and Greenery, 2014). Generalmente se utilizan bioplaguicidas como mecanismos de control para evitar el esparcimiento de las enfermedades, pero debido a que gran parte de los bioplaguicidas registrados en Colombia están

basados en microorganismos ya conocidos y que gran parte de éstos han sido reportados en países desarrollados y obtenidos por medio de colecciones internacionales (Bettioli, W.; Rivera, M.; Mondino, P.; Montealegre, J.; Colmenárez, 2014), no se garantiza la prevención y esparcimiento de enfermedades en cultivos Colombianos.

Un ejemplo de esto es el informe presentado en 2013 por la Universidad Nacional, dónde en el Oriente Antioqueño, principal productor y exportador a Estados Unidos de crisantemo, pese a haber desarrollado una gran campaña contra la roya blanca (Pacioni, 1982) amparada por la resolución 2641 del 22 de noviembre de 2004 (Rojas Vega, 2011), se detectó la presencia de esta enfermedad en alrededor de 800 hectáreas cultivadas en la región. Gracias al estudio de enfermedades en plantas que adelanta la Universidad Nacional se ha logrado identificar alrededor de 500 especies de roya (roya blanca de crisantemo, de la cebolla, gladiolo, etc.) (Rojas Vega, 2011), pero los mecanismos de prevención y control actuales no logran ser suficientes.

Una de las grandes problemáticas a las que se hace frente en el momento, es la baja eficiencia de los sistemas de monitoreo disponibles para la detección y prevención de plagas, esta tiene un gran impacto tanto productivo como económico en la industria floricultora debido a que es una variable permanente desde la plantación del cultivo hasta su recolección. El monitoreo de plagas y enfermedades es realizado a través del diagnóstico visual por medio de monitores que deben recorrer los cultivos revisando hoja a hoja con el fin de garantizar la no existencia de plagas tales: como minador, trips, Virus del marchitamiento moteado del tomate (TSWV), ácaros (*Tetranychus spider*), roya blanca, et (Castaño Duque & Restrepo, 2014). Este método de control de calidad se encuentra sujeto a errores de interpretación por parte de los operarios, ya que los síntomas visuales pueden presentarse simultáneamente y confundirse la causa de la enfermedad, por lo tanto, el proceso depende enteramente de la experticia y conocimientos con los que cuentan los operarios lo que dificulta generar muestreos homogéneos que den garante del buen estado de los cultivos (Barbedo, 2016).

Para cultivos de crisantemo, solo considerando la roya blanca se requiere una persona por hectárea dedicada exclusivamente al monitoreo de esta enfermedad, esto con el fin de garantizar estándares internacionales y cumplir con normativas dadas por el numeral 3 de la resolución ICA 578 del 26 de

marzo de 1997 (Instituto Colombiano Agropecuario, 1997). Para el 2015 este monitoreo equivalió a un costo de \$1.065.476/hectárea/mes, considerando costos adicionales del salario más prestaciones legales y parafiscales, esta cifra asciende a \$681 millones/mes más \$8.000 millones/año para un aproximado de 639 hectáreas de plantación de crisantemo en Antioquia. Este valor puede incrementar considerando el costo del uso de pesticidas para el control de la enfermedad, y en el caso de su uso excesivo se corre el riesgo de dejar residuos en los cultivos. Hecho que se puede presentar con relativa facilidad, ya que la mayoría de las enfermedades se distribuyen en grupos focales a través de los cultivos, pero los pesticidas son esparcidos uniformemente en los campos como medida de control.

Otra consideración son aquellas flores con plagas o enfermedades en las cuales la baja eficiencia de los sistemas de monitoreo permite que salgan hacia los procesos de despacho, ya que sus problemas no fueron detectados a tiempo en los procesos de cosecha y postcosecha. Esto termina generando pérdidas económicas, ya sea porque deben ser incinerados, o porque pasa los mecanismos de control locales y finalmente es detectado por la aduana de los países importadores. Allí, al no cumplir las normas fitosanitarias requeridas, el producto puede ser reexportado al país de origen o quemado en el lugar. Además, se puede generar la imposición de multas al exportador y finalmente pérdida de clientes por el incumplimiento a normativas o retrasos.

Como solución a estas problemáticas, en los últimos años se ha desarrollado un nuevo campo de investigación determinado como agricultura de precisión donde se busca la implementación de nuevas tecnologías en los procesos agrícolas alrededor del mundo. Un ejemplo de esto es la revisión presentada por Li et al. (2014), donde se da una recopilación de las técnicas usadas para el fenotipado de plantas, dentro de éstas se encuentra el uso de imágenes de luz visible, térmicas, fluorescentes, multiespectrales, 3D, entre otras.

Otro ejemplo es el desarrollo de un sistema de visión artificial, compuesto por una cámara a color, receptores GPS, paneles industriales y un sistema hidráulico con el objetivo de servir como sistema de precisión guía en los procesos de deshierbe mecánico en plantaciones agrícolas (Meng et al., 2015). Por otra parte, se presenta el desarrollo de índices vegetales, los cuales permiten realizar evaluaciones cualitativas y cuantitativas del vigor de las hojas, su estado de crecimiento, variedad de las plantas, entre otros (J. Zhang et al., 2017). Otros trabajos se enfocan en realizar una revisión

de los mayores desarrollos y aplicaciones de estos índices vegetales, considerados como una valiosa herramienta en la agricultura de precisión (Xue & Su, 2017). Esto último, se hace visible en trabajos como el de (Lunadei et al., 2012) que hace uso de estos índices en combinación con sistemas de visión artificial, para el monitoreo de hojas de espinaca a través de imágenes multiespectrales. De esta manera la implementación de técnicas de visión artificial en procesos agrícolas tales como el control de calidad, control fitosanitario, reconocimiento y manejo de especies, son una posible alternativa en la búsqueda de soluciones a estas problemáticas. Con esto en mente, se considera que la implementación de un sistema de visión artificial basado en el análisis de imágenes multiespectrales centrado en zonas de interés espectral permite la identificación de problemas fitosanitarios en plantas de crisantemo (trips, virus del marchitamiento moteado del tomate (*TSWV*) y ácaros (*Tetranychus* sp)) cercana a la de un monitor experto puede brindar alternativas en el desarrollo de la industria agrícola colombiana.

El objetivo alcanzado en esta tesis de maestría es el desarrollo de una metodología para la detección de plagas o enfermedades en hojas de crisantemo por medio de un sistema de visión artificial de laboratorio basado en imágenes multiespectrales. Para alcanzar este objetivo, en esta tesis se han llevado a cabo las siguientes etapas:

- Determinar por medio de análisis espectroscópico aquellas enfermedades susceptibles de estudio de acuerdo con su comportamiento espectral: en este objetivo fue generado un procedimiento de recolección y transporte de material vegetal recolectado en cultivos de flor nacional ubicados en la Ceja, Antioquia, seguido de la calibración de equipos ópticos (espectrofotómetro), acompañado de la lectura y procesamiento de firmas espectrales y finalmente se presenta un análisis comparativo del comportamiento espectral presentado en hojas de crisantemo afectadas por los problemas fitosanitarios objeto de estudios: trips, virus del marchitamiento moteado del tomate (*TSWV*) y ácaros (*Tetranychus* sp), permitiendo determinar de esta manera aquellos que sean susceptibles a ser objeto de estudio de acuerdo con su comportamiento espectral.
- Optimizar un prototipo básico de laboratorio para la captura de imágenes espectrales: para el desarrollo de este objetivo fue utilizado un sistema de iluminación LED que es resultado

del trabajo de grado de estudiantes de Ingeniería Mecatrónica del ITM. Este está compuesto de 10 canales de iluminación, a estos fue agregado un canal más, para un total de 11 canales disponibles. También se adaptó una cámara monocromática y se hizo el montaje de la estructura del sistema de captura multiespectral. Adicionalmente, se realizaron las configuraciones necesarias tanto de software como de hardware para el control integral del sistema.

- Desarrollar una metodología para la detección de enfermedades en plantas de crisantemo a partir de imágenes espectrales: en este se hizo uso de los resultados obtenidos en el primer objetivo, definiendo así aquellas enfermedades a ser estudiadas, adicionalmente fue utilizado el sistema de captura multiespectral calibrado y optimizado en el segundo objetivo. Finalmente, fue determinada una metodología para el procesamiento de las imágenes multiespectrales, que permitiera identificar aquellas regiones en las hojas que manifestaran presencia alguna de las enfermedades de interés.
- Evaluar técnicas de clasificación para el reconocimiento de enfermedades en plantas de crisantemo: en este objetivo fueron evaluados algoritmos de clasificación que permitieran la identificación de las enfermedades seleccionadas, para esto se construyó una base de datos de imágenes multiespectrales de hojas de crisantemo que presentaran las enfermedades de interés, con ayuda de un Ingeniero Agrónomo experto en el reconocimiento de problemas fitosanitarios.

1. Marco Teórico y Estado del Arte

En la última década ha crecido el interés de la comunidad científica por implementar tanto tecnologías de espectroscopía, como de visión computacional integradas a herramientas de inteligencia artificial en sistemas de monitoreo visual en la agricultura de precisión. Estas herramientas son valiosas ya que, por ejemplo, en el caso de diagnóstico de enfermedades y plagas, pueden ser más rápidas, sencillas y prácticas que los métodos más comunes basados en análisis de laboratorio los cuales dependen de complejas técnicas bioquímicas, microbiológicas, de biología molecular e identificación entomológica (Izzuddin et al., 2017; Jin et al., 2017; Veys et al., 2019; S. Zhang et al., 2018).

Por su parte, la espectroscopía en general estudia la interacción de la radiación electromagnética con la materia. Sus aplicaciones pasan por áreas como la biología, la química, la física entre otras disciplinas, no sólo en el campo científico, sino también en el de las aplicaciones industriales. Esta disciplina se sigue desarrollando actualmente, y en el área biológica y de la agricultura, ha sido una técnica ampliamente utilizada en la determinación de las condiciones biológicas de las plantas, al utilizar como mecanismo de medición variables que evidencian sus cambios. Específicamente, la espectroscopía de reflectancia se usa en la determinación de índices vegetales que, valiéndose de la combinación adecuada de mediciones en diferentes rangos espectrales, permite establecer cuantitativamente el estado de las plantas (Wahabzada et al., 2016). Sin embargo, las mediciones espectrofotométricas se llevan a cabo punto a punto lo que hace que una información detallada en áreas amplias de las plantas sea de difícil adquisición.

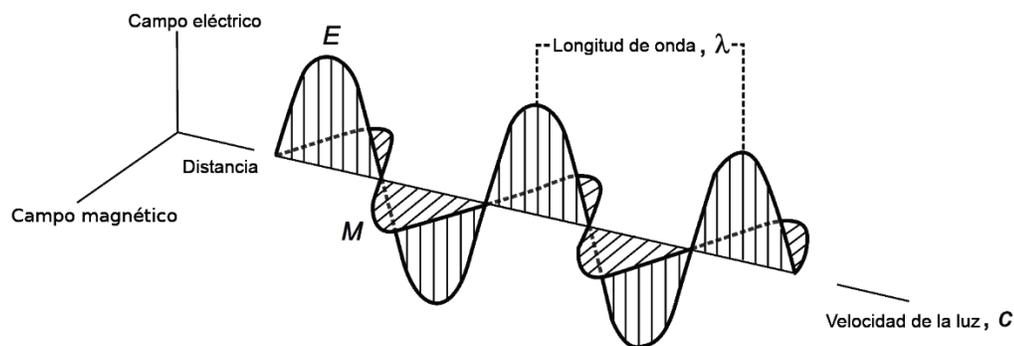
Por otro lado, los sistemas de visión artificial también han sido usados para detectar enfermedades o sus efectos al analizar ya sean cambios en la coloración de las plantas, o las geometrías características de las sintomatologías mediante técnicas de procesamiento incluidas técnicas de inteligencia artificial (Perez-Sanz et al., 2017). No obstante, la buena resolución espacial que pueden ofrecer estos sistemas, con ellos la información espectral queda limitada al rango visible a través de 3 canales típicos RGB o a regiones espectrales amplias como el infrarrojo cercano. Es así como los sistemas de imágenes espectrales (multiespectrales o hiperespectrales dependiendo de la cantidad de canales) se ubican en un estado intermedio que intenta aprovechar las ventajas de la espectroscopía y los sistemas de visión artificial agrupando en un sistema tanto altas resoluciones

espaciales como capacidades de discriminación espectral punto a punto. De esta manera, el propósito de este estado del arte es revisar los elementos y trabajos más relevantes de las áreas de la espectroscopía de reflexión y la visión computacional en la agricultura de precisión, más específicamente en el análisis de plantas.

1.1 Espectro electromagnético

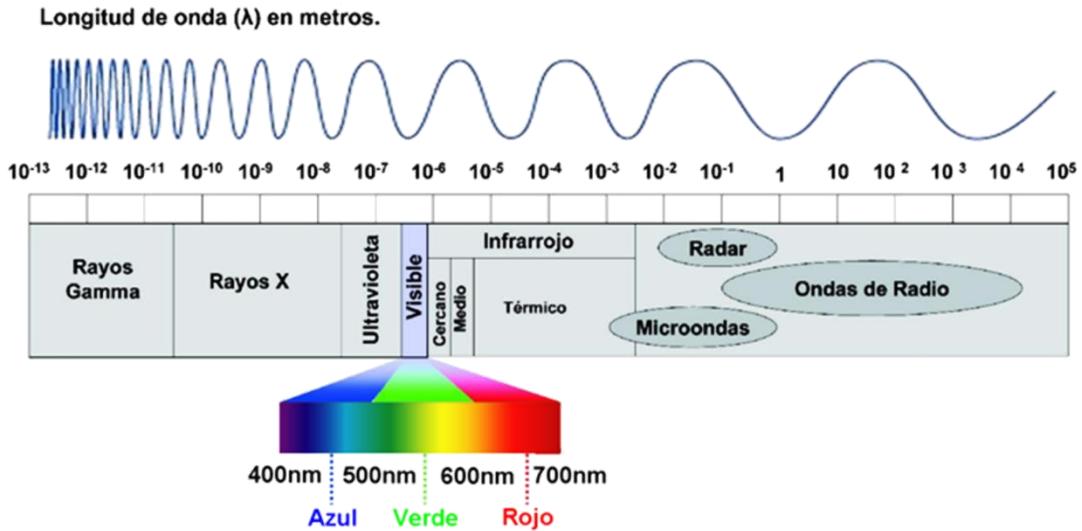
La energía electromagnética (EM) puede ser modelada de diferentes maneras, ya sean ondas o energía compuesta por partículas denominadas fotones; en el primer caso se considera que la energía se propaga por el espacio en forma de ondas sinusoidales, éstas son caracterizadas por campos eléctricos (E) y magnéticos (M) perpendiculares uno con el otro. Como se puede observar en la Figura 1-1 una de las características más importantes de las ondas electromagnéticas es su longitud de onda, la cual se determina como la distancia entre crestas sucesivas de ondas que es medida ya sea en metros (m), nanómetros ($\text{nm} = 10^{-9}\text{m}$) o micrómetros ($\mu\text{m} = 10^{-6}\text{m}$) (Dyring, 1973).

Figura 1-1: Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética (figura tomada de Dyring, 1973).



La radiación emitida por toda materia que presente una temperatura mayor al cero absoluto (0°K) emana ondas electromagnéticas en múltiples longitudes de onda, la totalidad del rango en que se presentan se denomina espectro electromagnético, que va desde los rayos gamma hasta las ondas de radio, en la Figura 1-2 se puede observar como éste está compuesto de múltiples regiones.

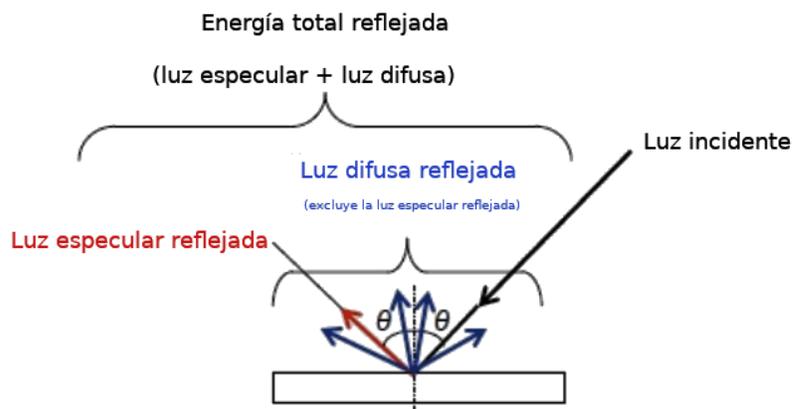
Figura 1-2: Clasificación del espectro electromagnético (figura tomada de Estudios & Centro, 2017).



1.2 Sistemas espectrométricos

La espectroscopía es una técnica que permite medir las características espectrales de absorción/reflexión de diferentes materiales. En la reflexión, al incidir un haz de luz generado por una fuente artificial sobre una muestra, la energía reflejada por ésta se capta usando un sensor en un espectrómetro, el cual se encarga de separar la información recibida de acuerdo con su longitud de onda. La representación de esta señal es conocida como firma espectral. El rango de medición espectral de estos sistemas depende de sus características ópticas y puede abarcar múltiples regiones del espectro electromagnético.

Para determinar la cantidad de energía reflejada por un objeto, deben ser medidas tanto la cantidad de energía dispersada como la energía incidente sobre una muestra. Para esto es necesario calibrar la luz incidente, determinando la intensidad reflejada por un material estándar que tenga un comportamiento espectral ya definido (Klima, 2012). El total de la energía reflejada está compuesto por la suma de la luz especular (energía reflejada en el mismo ángulo de la luz incidente) y difusa (energía reflejada en todas las direcciones), como se observa en la Figura 1-3.

Figura 1-3: Medición de reflectancia total relativa (figura adaptada de Shimadzu, 2019).

La cantidad de energía reflejada puede ser determinada como reflectancia relativa o absoluta, en el primer caso se calcula la cantidad proporcional de luz reflejada de una muestra relativa a la cantidad luz reflejada por un material estándar (ver Ecuación (1.1)), por otra parte, la reflectancia absoluta representa la cantidad proporcional de luz reflejada de una muestra relativa a la cantidad luz proveniente directamente de la fuente de luz (ver Ecuación (1.2)) (Shimadzu, 2019).

$$\text{Reflectancia relativa (R\%)} = \frac{\text{Cantidad de luz reflejada por la muestra}}{\text{Cantidad de luz reflejada por un material estándar}} \times 100 \quad (1.1)$$

$$\text{Reflectancia absoluta (R\%)} = \frac{\text{Cantidad de luz reflejada por la muestra}}{\text{Cantidad de luz utilizada}} \times 100 \quad (1.2)$$

La espectroscopía de reflectancia ha sido una técnica útil en la caracterización de objetos por medio de la medición de la reflexión de la radiación electromagnética en ellos. Esta técnica permite un amplio rango de trabajo y sólo requiere someter la muestra a un haz de luz incidente. Esto ha hecho de esta técnica una herramienta útil para el análisis y caracterización no invasivos de las plantas, ya que la interacción de la luz con éstas se puede ver afectado debido a cambios fisiológicos o problemas en su estructura, es decir, estos cambios o problemas se hacen evidentes en las propiedades ópticas de las plantas.

Dentro de las aplicaciones de la espectroscopía se encuentra el fenotipado de plantas (Ashourloo et al., 2014; Leucker et al., 2015), que ha brindado información relevante permitiendo estudiar la diversidad genética que se presenta tanto en plantas como en los patógenos que las afectan. Por

medio de esta información se obtiene información espectral que permite caracterizar dicha diversidad de manera que se han logrado diferenciar los cambios fisiológicos a los que son sometidos las plantas bajo la presencia de dichos patógenos.

Por medio del análisis de los cambios en la respuesta espectral de las plantas se han desarrollado índices vegetales (Xue & Su, 2017); estos índices han servido como base para la detección de estrés o enfermedades con una efectividad reportada de hasta el 70% (Ashourloo et al., 2014). Para realizar este proceso es necesario contar con un profesional experto en el tema; todo el procedimiento es laborioso debido al requerimiento constante de someter las muestras a sondas de contacto, esto implica grandes cantidades de tiempo para la extracción y caracterización de la información. Por esto se requiere de técnicas que optimicen, simplifiquen y mejoren los resultados obtenidos.

1.3 Sistemas de visión artificial

La visión artificial es el campo científico que se encarga del procesamiento de imágenes digitales y la extracción de información valiosa de éstas, con el objetivo de realizar múltiples tareas como lo pueden ser la medición de un espacio para navegación, aplicaciones de realidad aumentada, reconocimiento de formas o elementos, etc. Este campo lleva alrededor de 50 años de desarrollo, y aunque se han logrado grandes avances, aún el resultado ofrecido por estos sistemas no es enteramente comparable con el poder de procesamiento humano, dada la dificultad de dar significado a un píxel (mínima unidad de medida en una imagen) y el mundo real, algo que el cerebro humano realiza con facilidad (Krishna, 2017).

Los sistemas de visión artificial también han sido usados para detectar enfermedades o sus efectos al analizar ya sean cambios en la coloración de las plantas, o las geometrías características de las sintomatologías mediante técnicas de procesamiento, incluidas técnicas de inteligencia artificial. A pesar de la buena resolución espacial que pueden ofrecer estos sistemas, con ellos la información espectral queda limitada al rango visible a través de 3 canales típicos RGB o a regiones espectrales amplias como el infrarrojo cercano. Es así como los sistemas de imágenes multi o hiperespectrales se ubican en un estado intermedio que intenta aprovechar las ventajas de la espectroscopía y los sistemas de visión artificial agrupando en un sistema tanto altas resoluciones espaciales como

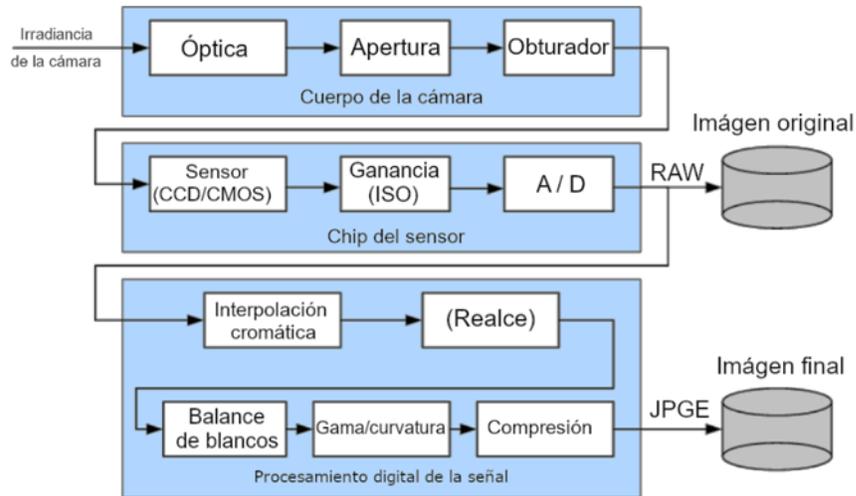
capacidades de discriminación espectral punto a punto. De esta manera, el propósito del estado del arte consultado es revisar los elementos y trabajos más relevantes de las áreas de la espectroscopía de reflexión y la visión computacional en la agricultura de precisión, más específicamente en el análisis de plantas.

Una de las grandes ventajas de los sistemas de visión artificial para el análisis de plantas se da por ser un método no destructivo. Este permite determinar a partir de una imagen la presencia de enfermedades tomando mediciones computacionales y estadísticas basadas en regiones de interés constituidas por píxeles y su ubicación espacial en la imagen. Estas regiones pueden partir de información dada por características como el color, la textura, el tamaño, la forma, la superficie, entre otras (Behmann et al., 2014). A su vez, estos sistemas integrados con la inteligencia artificial brindan un campo de aplicación más amplio para la identificación de plagas y enfermedades. Por lo general, estos se basan en el uso de equipos electrónicos comerciales para obtener imágenes de alta resolución de las hojas, estas imágenes son luego procesadas, clasificadas e identificadas por algoritmos de inteligencia artificial (Anand et al., 2016).

1.3.1 Formación de la imagen

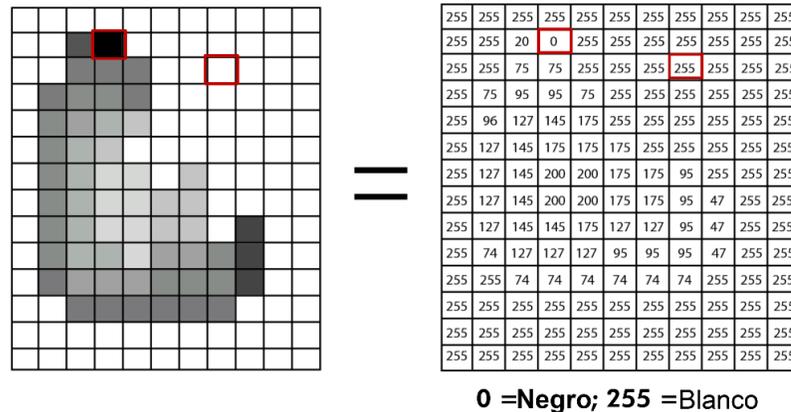
Las imágenes digitales son una representación de un objeto sensible de ser capturado por una cámara. Esta cámara recibe la energía reflejada por el objeto y ésta es procesada y convertida en una imagen digital (ver **Error! Reference source not found.**) al realizar una proyección de una escena tridimensional en un plano de proyección bidimensional interpretado como una función $f(x, y)$, donde x, y representan la ubicación de un pixel el cual registra un valor de intensidad (Tyagi, 2018).

Figura 1-4: Proceso de captura de imágenes donde se muestran los diversos pasos típicos de post-procesamiento digital (imagen adaptada de Szeliski, 2010).



Computacionalmente, como se puede observar en la Figura 1-5, la imagen es representada como una matriz bidimensional que contiene una cantidad determinada de píxeles con valores de intensidad que pueden abarcar diferentes rangos de valores, siendo el más común el rango que va de 0-255 para lo que se determina como imágenes de 8 bits (Tyagi, 2018).

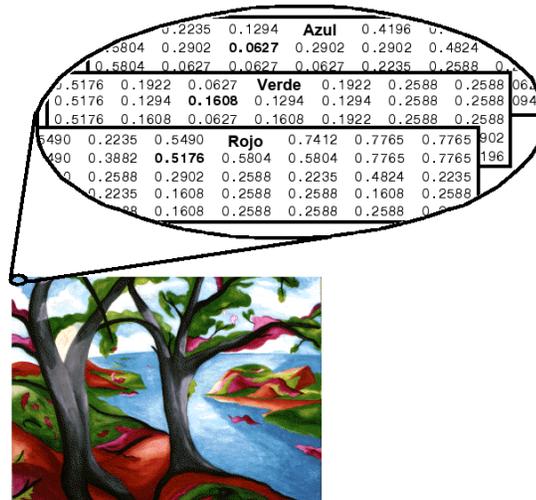
Figura 1-5: Representación computacional de una imagen (imagen tomada de Media Production Lab, 2019).



1.3.2 Imágenes en el rango visible

Las imágenes en el rango visible del espectro electromagnético se caracterizan por estar compuestas de un arreglo matricial tridimensional caracterizado por un alto, ancho y profundidad, esta última está compuesta por tres componentes, donde cada componente representa una matriz bidimensional que alberga los diferentes valores de intensidad para esa componente. El espacio de color RGB es el más utilizado actualmente, éste se conforma por las componentes roja (R), verde (G) y azul (B) por sus siglas en inglés, el conjunto de estas tres matrices genera lo que es percibido como una imagen a color como se observa en la Figura 1-6 (Tyagi, 2018).

Figura 1-6: Representación matricial de una imagen RGB (figura tomada de Matlab, 2019).



Los sistemas de visión artificial brindan gran facilidad para la adquisición de información a través de cámaras digitales. Estas cámaras son cada vez de mejor desempeño y más fácil acceso comercial. Así, en la literatura se encuentra un extenso grupo de trabajos que emplean visión artificial para las problemáticas de identificación de plagas o enfermedades en plantas y desde diferentes acercamientos. Por una parte, se encuentran técnicas enfocadas en los cambios de color presentados en las hojas de cidro como síntomas causados por la presencia de plagas o enfermedades (Ali et al., 2017). Otros autores se enfocan en formaciones de color para la clasificación de las enfermedades (Barbedo et al., 2016), operaciones booleanas en el proceso de segmentación (Barbedo, 2017) o ecualización del histograma junto con estructuras de transformación de color (Anand et al., 2016). En general, las técnicas clásicas de segmentación y

color presentan buenos resultados, aunque, ya que la iluminación juega un papel importante, en algunos casos se hacen necesarios entornos controlados en la adquisición lo que mejora el desempeño en su implementación.

Otros trabajos al contar con mayor información de sus problemáticas se enfocan en abordar los algoritmos de clasificación para mejorar sus resultados, ya sea usando técnicas de toma de decisiones de criterios múltiples (Goodridge et al., 2017), representaciones dispersas (Ma et al., 2017) e incluso técnicas más recientes como el aprendizaje profundo (Roy et al., 2020).

Aunque se presentan resultados positivos en la implementación de sistemas clásicos de visión artificial, es de notar que se basan en información tomada en el rango de la luz visible, sin tener en consideración información valiosa para la agricultura de precisión que puede adquirirse en otros rangos del espectro electromagnético. Técnicas más modernas como el aprendizaje profundo (Roy et al., 2020) dan solución a las problemáticas presentadas en los procesos de segmentación y cambios dados en el ambiente, pero para esto requieren de la recolección de gran cantidad de imágenes que garanticen la generalización de sistema, e igualmente sistemas de computación de alto rendimiento para el procesamiento de la información.

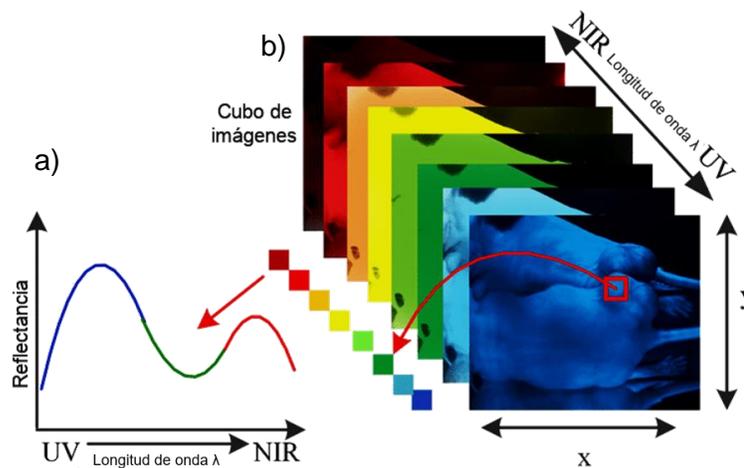
1.3.3 Imágenes multiespectrales e hiperespectrales

A diferencia de las imágenes que operan en el rango visible del espectro electromagnético, las imágenes espectrales están compuestas de una cantidad n de canales aparte de los comúnmente conocidos (RGB), donde cada uno de éstos representa una longitud de onda del espectro electromagnético (ver Figura 1-7a) y una vez capturado es organizado capa a capa formando un cubo de datos espectral con dimensiones x, y, z , siendo z una cantidad λ de bandas espectrales generadas por una fuente de iluminación artificial diseñada para emitir energía a una longitud de onda en particular (ver Figura 1-7b) (Sowmya et al., 2019). De esta manera, cada píxel representa un vector unidimensional en el espacio espectral formado por la cantidad de bandas que lo conforman.

Las imágenes espectrales se pueden dividir en dos grandes grupos: multiespectrales e hiperespectrales, aunque se pueden encontrar otras divisiones diferentes, sin embargo, esta

división es la más común. El uso de un término u otro depende de la cantidad de bandas de longitud de onda y distancia en nanómetros entre cada banda espectral. Las imágenes multispectrales se enfocan en generar imágenes bidimensionales de unas pocas a decenas de bandas generalmente separadas por una cantidad significativa de nanómetros en el espectro electromagnético, mientras las imágenes hiperespectrales obtienen un cubo tridimensional de imágenes compuestas por cientos o inclusive miles de diferentes longitudes de onda, separadas entre ellas por unos cuantos nanómetros (ver Figura 1-7). De esta manera, las imágenes multispectrales permiten un procesamiento más fácil y rápido contando con una menor cantidad de datos espectrales, en contraste, las imágenes hiperespectrales brindan una alta resolución espectral, pero son más exigentes en su procesamiento (Sowmya et al., 2019).

Figura 1-7: Imagen espectral: a) representada como respuesta espectral, b) como un arreglo tridimensional (x, y, λ) (figura adaptada de Sowmya et al., 2019).



La identificación de regiones espectrales que brinden información relevante para la detección de enfermedades ha sido una técnica empleada como solución a algunas de las problemáticas planteadas, ya que estas regiones permiten obtener información de la salud de la planta. A través de imágenes se puede analizar en un rango específico del espectro de la luz los cambios en reflectancia debido al efecto en las características biofísicas y bioquímicas de las hojas por la presencia de una infección o parásitos (Fang & Ramasamy, 2015).

El uso de ésta técnica se ha hecho popular en los últimos cinco años en la detección de enfermedades en plantas, encontrando en la literatura trabajos que combinan los resultados del análisis espectroscópico y regiones multiespectrales o hiperespectrales con sistemas de clasificación, con el objetivo de mejorar estos procesos, ya sea por medio de métricas de preprocesamiento espectral o el análisis del espacio de datos espectral obtenido (Marques et al., 2016; Thomas et al., 2018).

Dentro de estos trabajos se presentan diferentes acercamientos tanto para la identificación de características como para la clasificación entre hojas sanas y afectadas por plagas o enfermedades. Un ejemplo es el trabajo de (Thomas et al., 2018), dónde se hace una revisión de diferentes tipos de redes neuronales en el análisis de información espectral, con el objetivo de desarrollar nuevos índices de enfermedad espectral (SDI), que son la proporción de diferentes bandas espectrales que puedan ser utilizadas para el diagnóstico de enfermedades.

Por otro lado, otros autores se enfocan en la región del infrarrojo cercano y onda corta para la identificación de las afecciones sanitarias (hongos). El trabajo sobre frutos de maní presentado por (Qiao et al., 2017), quienes utilizaron el análisis de varianza (ANOVA) como método de selección de características junto con extracción de características por medio de ponderación no paramétrica, finalmente implementan la clasificación de las muestras con máquinas de soporte vectorial (SVMs). En un trabajo en plantas de guisantes se realizó la extracción de características estadísticas basadas en el histograma, éstas fueron clasificadas usando análisis basados en análisis lineal discriminante (LDA) y análisis cuadrático discriminante (QDA) (Karuppiah et al., 2016). Aunque estos trabajos muestran que la región del infrarrojo cercano y onda corta aportan buena información para la clasificación de problemas fitosanitarios, desde el punto de vista de aplicación práctica tienen limitaciones por los costos tanto de los elementos ópticos necesarios en el sistema de adquisición como por los sensores de captura. Los sensores basados en óxido de silicio para el visible son mucho más comerciales que los sensores en el infrarrojo que por su proceso de fabricación y material sensible son mucho más costosos, lo que dificulta su implementación y en un mediano plazo su uso generalizado en una industria como la floricultora.

Se hace evidente en la literatura trabajos usando diversas técnicas en diferentes zonas del mundo para múltiples tipos de cultivos en el campo creciente de la agricultura de precisión (Sowmya et al., 2019). Esto pone de manifiesto una especificidad de estas metodologías en cuanto a los problemas a detectar, las plantas de interés, y a su vez, en la implementación de la técnica o técnicas de análisis y detección. En consecuencia, y dada la especificidad de estas soluciones, es que surge la necesidad de un estudio que desarrolle una metodología propia en nuestro contexto. En Colombia, puntualmente en Antioquia, éste es un campo que recién se está explorando y logrando avances. Así, el uso de visión artificial con imágenes espectrales en nuestro medio muestra ser una estrategia que puede aportar soluciones efectivas. Si además se considera la importancia de la industria floricultora como músculo económico de la región, y en específico de la flor del crisantemo, este problema se hace más pertinente debido a que aún son empleados métodos clásicos manuales para la inspección e identificación de plagas o enfermedades en sus cultivos.

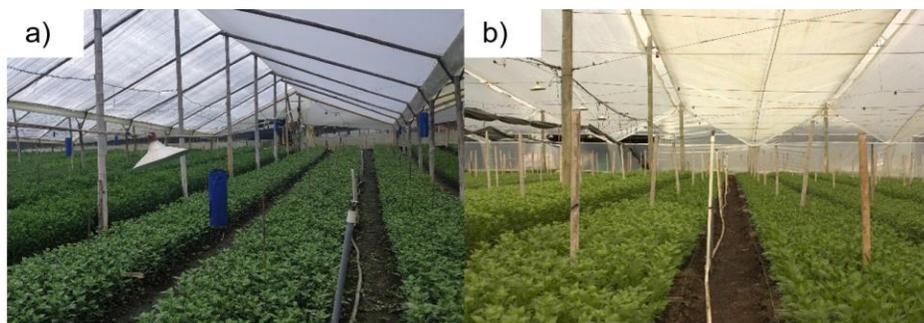
En la literatura se encuentran reportados trabajos que exploran las respuestas espectrales en hojas de crisantemo, pero estos se enfocan en la identificación taxonómica de sus variedades utilizando espectroscopía Raman (Zhu et al., 2017) y espectroscopía en el infrarrojo cercano (Rodríguez-Moreno et al., 2017). En cuanto al uso de visión artificial, ésta se ha usado para determinar la variedad de crisantemo usando imágenes de las hojas y su representación en el espacio de escalas de curvaturas (CSS) (Abbasi et al., 1997). Finalmente, se ha encontrado una mención corta a la medición del daño causado por trips en hojas de crisantemo usando sistemas de imágenes hiperespectrales (Wageningen, 2016). Para esta mención, que se hace en una página web, sin detalles claros y que sería de especial interés en esta propuesta, no se encontró publicación científica alguna que mostrara los detalles metodológicos y el alcance de los resultados. Tomando en consideración esto, se hace claro tanto el interés científico como la necesidad práctica del desarrollo de metodologías para determinar el efecto que tienen las diferentes afecciones sobre las plantas de crisantemo y que apoyen la mejora de los procesos de calidad y/o productividad usando nuevas tecnologías.

2. Determinación de problemas fitosanitarios susceptibles de estudio

El siguiente capítulo describe los procedimientos, técnicas, actividades y demás estrategias metodológicas utilizadas durante la investigación e igualmente los resultados obtenidos, tales como: el protocolo empleado para el transporte de material vegetal, de igual forma, se determinó el protocolo de medición espectral óptimo para la lectura de los datos espectrales y finalmente, la descripción del procedimiento de lectura estos, así como la obtención de firmas de reflectancia de hojas de crisantemo y la comparativa entre hojas sanas versus aquellas con presencia de enfermedades (TSWM, trips y ácaros), con la finalidad de determinar aquellas regiones espectrales de interés.

Las muestras de hojas de crisantemos fueron recolectadas de cultivos de flor nacional en los pueblos de la Ceja (ver Figura 2-1a) y el Carmen de Viboral (Figura 2-1b) del departamento de Antioquia. Estos cultivos son para la producción de flor ornamental (uso en jardinería o decoración), dispuestos en una estructura tipo capilla (Agropimos, 2018), que es fácilmente identificada al contar con dos planos inclinados que conforman el techo del invernadero. Estos son recomendados para climas templados o fríos, lo que está de acuerdo con la ubicación geográfica del oriente antioqueño. Sobre esta estructura se dispone un plástico para la protección y acondicionamiento climático de los cultivos. Dentro del invernadero, las plantas se organizan por parcelas dispuestas paralelamente. Cada parcela a su vez se divide por camas, que corresponden a secciones cultivadas con una diferente variedad de flor.

Figura 2-1: Disposición de parcelas pertenecientes a cultivos de flor nacional. a) Invernadero ubicado en La Ceja, Antioquia, b) Invernadero ubicado en el Carmen de Viboral, Antioquia.



Aunque la flor cultivada es el crisantemo, ésta puede ser categorizada en diferentes tipos identificados por su taxonomía y morfología. De esta manera, los tipos de flores que son cultivadas en el oriente antioqueño son dos: el pompón, que se manifiesta en forma globular, constituidos por flores de pétalos radiales cortos y uniformes sin la presencia de pétalos concéntricos (ver Figura 2-2a); y araña, que presenta una forma redondeada donde los pétalos son radiales doblándose hacia afuera y hacia abajo (ver Figura 2-2b).

Figura 2-2: Flor de crisantemo. a) Tipo pompón, b) Tipo araña.



Aparte de esto, se pueden representar diferentes variedades en la flor, estas son nombradas por el productor de la semilla, su nombre describe el tipo de flor (coloración). Estos nombres se usan en las parcelas de tal manera que sean identificadas por productores y revisores para determinar la cantidad cultivada de una variedad, control fitosanitario en diferentes etapas de crecimiento, control de corte y despacho de los pedidos en etapa de floración (periodo de germinación de la flor). En la Figura 2-3 se observan parcelas con diferentes variedades de crisantemo en el inicio de la etapa de floración.

Figura 2-3: Plantación de diferentes variedades de flor de crisantemo en sus inicios de la etapa de floración.



2.1 Recolección y transporte de material vegetal

Para este trabajo, se recolectaron muestras de hojas de tres variedades de crisantemo: *Anastasia White*, *Margarita White* y *Anastasia Dark Green*. Esto dado que, al momento de la recolección de muestras, en estas tres variedades se encontraron los problemas sanitarios de interés: trips, virus del marchitamiento moteado del tomate (TSWV) y ácaros (*Tetranychus* sp.).

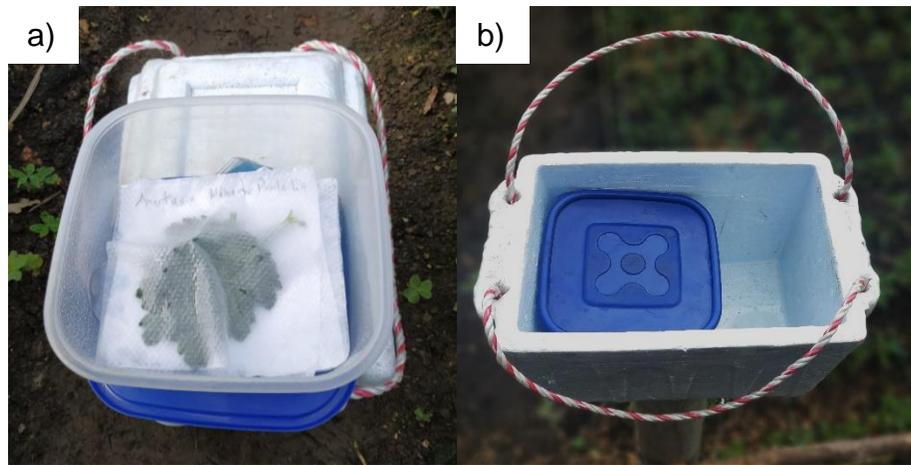
El proceso de recolección de muestras se llevó a cabo siguiendo la guía para toma y transporte de muestras vegetales dada por el Instituto Colombiano Agropecuario (ICA) en el 2008 (Instituto Colombiano Agropecuario, 2008) (Figura 2-4). Este procedimiento se hizo con el acompañamiento del Ingeniero Agrónomo Andrés Mario Cardona Puerta, quién se ha desempeñado como revisor experto en el reconocimiento visual de problemas fitosanitarios en el ICA. De esta manera se garantizó la fiabilidad de las muestras en cuanto a las variedades y la presencia de las enfermedades de interés.

Figura 2-4: Procedimiento de reconocimiento y recolección de material vegetal.



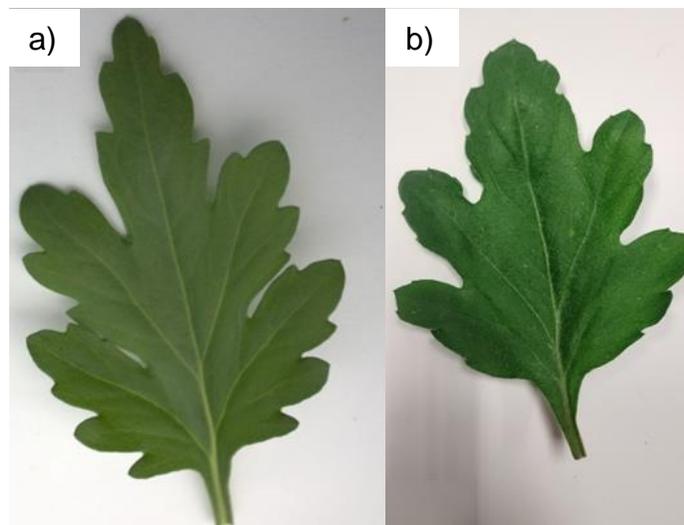
Como se observa en la Figura 2-5a, el material recolectado fue envuelto en toallas de papel humedecidas y posteriormente empacado en recipientes de plástico limpios, cerrados herméticamente e identificados con etiquetas externas. De esta manera se separaron los diferentes grupos de hojas con presencia de alguna enfermedad dentro del recipiente plástico. Estos fueron almacenados con hielo en una nevera de poliestireno expandido (ver Figura 2-5b), para evitar la deshidratación del tejido recolectado o su exposición al sol durante su transporte al laboratorio de visión Artificial y Fotónica del Instituto Tecnológico Metropolitano (ITM).

Figura 2-5: Almacenamiento y transporte de material vegetal. a) Empacado y almacenamiento de muestras recolectadas; b) Transporte de material vegetal seleccionado.



El protocolo implementado logró la conservación adecuada de las muestras, ya que las hojas en el laboratorio preservaron una apariencia muy similar a la del cultivo (Figura 2-6). Al prevenir la deshidratación, que se manifiesta como un arrugamiento del tejido vegetal, se evitó afectar negativamente cualquier medición realizada sobre la muestra.

Figura 2-6: Captura de hojas de crisantemo en campo y en laboratorio. a) Hoja de crisantemo en campo antes de ser empacada; b) Hoja de crisantemo en el laboratorio después de haber sido transportada.

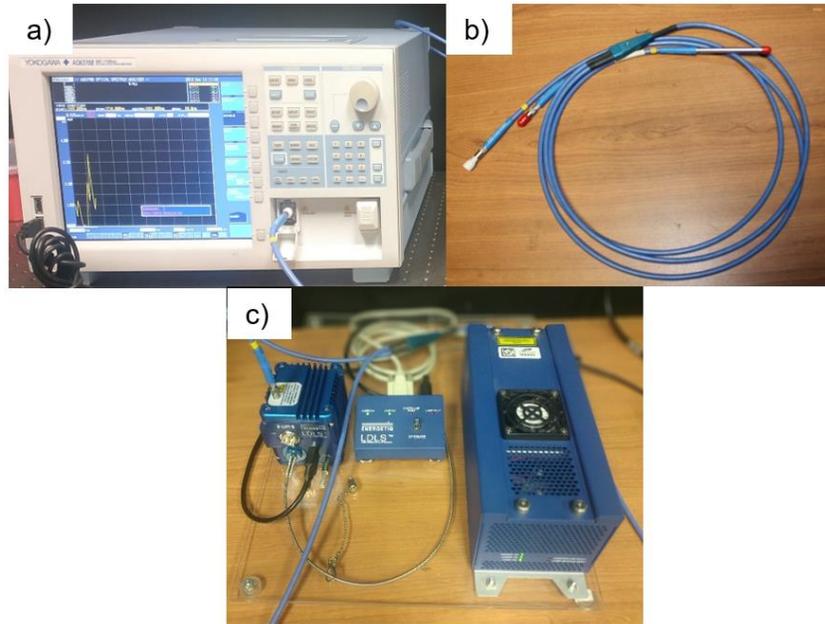


2.2 Adquisición de firmas espectrales

Para garantizar que los resultados obtenidos sean coherentes y confiables, se determinaron los parámetros óptimos de medida con el espectrofotómetro (ver Figura 2-7a), por medio de un proceso de calibración. Este es un equipo de alta precisión marca Yokogawa, modelo AQ6373, que tiene un rango de medición entre los 350 y 1100 nm (En el Anexo A se detallan las demás especificaciones técnicas). Este equipo es complementado por una sonda y una fuente de luz blanca de espectro ancho. La sonda es una fibra óptica *Ocean Optics* QR200-7-UV-VIS (ver Figura 2-7b) con un diámetro de núcleo de 200 μm y un rango de operación espectral de 400 a 2200 nm. La fuente de luz es una fuente de espectro ancho (luz blanca) inducida por láser Energetiq TM - EQ-99X LDLS (ver Figura 2-7c) que emite en el rango de 170 a 2100 nm (En el Anexo B se detallan las demás especificaciones técnicas). La sonda transmite la luz de la fuente a la muestra y es la encargada de llevar la luz reflejada de vuelta al espectrofotómetro.

Inicialmente, el proceso de medición de espectros fue validado mediante un conjunto de ajustes de los parámetros del montaje para garantizar información fiable. Para ello, se generó un protocolo de acuerdo con las condiciones de lectura y las características de los equipos. Adicionalmente, los datos espectrales fueron normalizados con el fin de obtener una firma espectral característica de la muestra en términos de reflectancia.

Figura 2-7: Equipos medición de espectros. a) Espectrofotómetro Yokogawa AQ6373; b) Fibra óptica *Ocean Optics* QR200-7-UV-VIS; c) Fuente laser Energetiq TM – EQ-99X LDLS (Anexo B).



2.2.1 Protocolo de medición

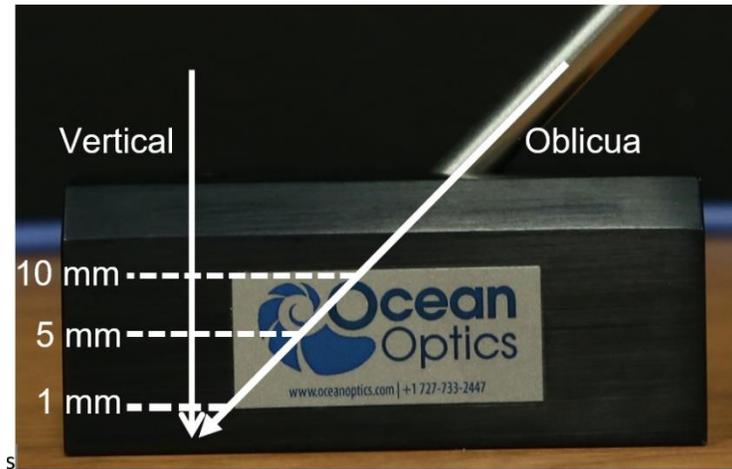
En este procedimiento fueron evaluadas tres diferentes configuraciones. Como parámetros a variar se usaron: la resolución de medida del equipo (*Resolution*), la cantidad de mediciones realizadas (*Average times*) para mejorar la relación señal ruido, y el intervalo de muestreo (*Sampling interval*), finalmente como constante se tiene el modo sentido (*Sense mode*) que determina la sensibilidad del espectrofotómetro. Estas configuraciones se observan en la Tabla 2-1.

Tabla 2-1: Configuraciones para los parámetros de medición del espectrofotómetro.

Parámetros	Configuración 1	Configuración 2	Configuración 3
<i>Resolution (nm)</i>	2.0	5.0	5.0
<i>Sense mode</i>	HIGH2	HIGH2	HIGH2
<i>Average times</i>	2	2	4
<i>Sampling Interval (nm)</i>	0.5	1	0.5

Por otra parte, se avaluó cuál es la disposición adecuada de la fibra óptica sobre un soporte especializado para este tipo de instrumentos. En la Figura 2-8 se pueden observar las condiciones evaluadas: ubicación de la fibra óptica (vertical y oblicua) y su distancia con relación a la muestra (1, 5 y 10 mm).

Figura 2-8: Posiciones evaluadas para la fibra óptica.



La Tabla 2-2 muestra los resultados obtenidos después de evaluar las 3 diferentes configuraciones propuestas del espectrómetro junto con las condiciones de posición (oblicua o vertical) y distancia (1, 5 y 10 mm) de la fibra óptica. Para las diferentes combinaciones se evaluó si la muestra presentaba quemaduras por el haz de luz de la fuente o no. Se observa que, bajo una disposición vertical de la fibra óptica, esta genera daño sobre el tejido vegetal en las tres distancias evaluadas, contrario a esto la disposición oblicua de la fibra óptica presenta una menor cantidad de casos donde se halla presentado daño al tejido vegetal. Para las diferentes configuraciones se observa que para la tercera (3), solo en las condiciones de posición oblicua a una distancia de 5 y 10 mm la muestra no fue quemada, en el caso de la configuración 2 la muestra no presentó daños en posición oblicua y distancia de 10 mm.

Tabla 2-2: Resultados de pruebas calibración para el equipo de sensado y la disposición de la fibra óptica.

Posición	Distancia	Configuración 1	Configuración 2	Configuración 3
Oblicua	10 mm	Muestra quemada	Muestra no quemada	Muestra no quemada
Oblicua	5 mm	Muestra quemada	Muestra quemada	Muestra no quemada
Oblicua	1 mm	Muestra quemada	Muestra quemada	Muestra quemada
Vertical	10 mm	Muestra quemada	Muestra quemada	Muestra quemada
Vertical	5 mm	Muestra quemada	Muestra quemada	Muestra quemada
Vertical	1 mm	Muestra quemada	Muestra quemada	Muestra quemada

Estas pruebas permitieron determinar aquellos parámetros de medición del espectrofotómetro que brindaran una óptima relación señal/ruido en el proceso de medición, y evitaran daños al tejido vegetal en las zonas de muestreo. Considerando lo anterior, Por tanto, en la Tabla 2-3 se presenta el protocolo de medición seleccionado.

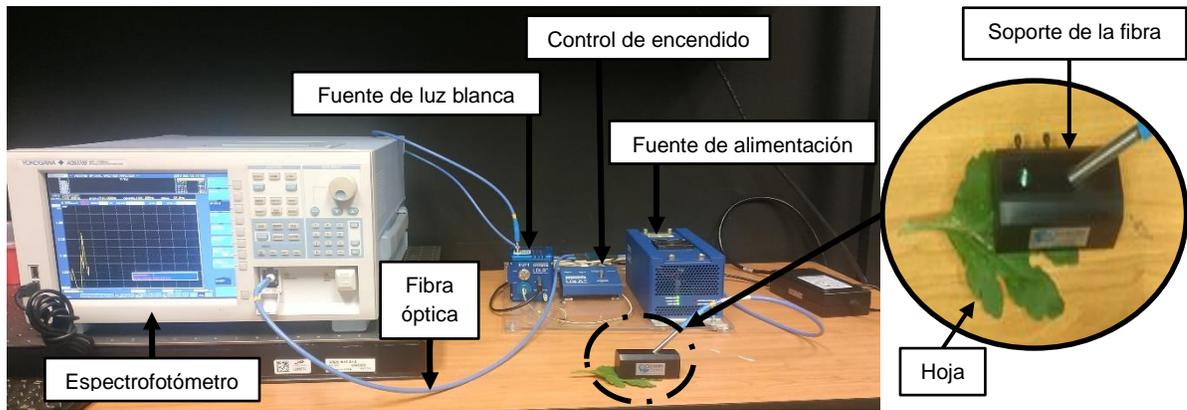
Tabla 2-3: Protocolo de medición espectral con el analizador de espectros ópticos Yokogawa AQ6373.

PARÁMETRO	UNIDAD
Resolución	5 nm
Modo de medición	HIGH2
Cantidad de promedios de muestreo	4
Intervalo de muestreo	1 nm
Posición de la fibra óptica	Oblicua
Distancia de la fuente de luz a la muestra	10 mm

2.2.2 Lectura de datos espectrales

Una vez determinado el protocolo de medición a utilizar, este fue implementado en el procedimiento de lectura de los datos espectrales, este fue llevado a cabo en el laboratorio de Visión artificial y Fotónica ubicado en la sección de parque i del bloque M ITM. Para esto, como se observa en la Figura 2-9 se ubicó el espectrofotómetro sobre una mesa con el objetivo de garantizar la estabilidad al equipo, posteriormente se realizó la conexión de la fibra óptica a la fuente de luz y el espectrofotómetro, finalmente se ubicó la salida de la fibra óptica sobre una base la cual cumple con el objetivo de: mantener de manera estática la fibra óptica garantizando estabilidad en la lectura de los espectros y mantener la hoja fija mientras la fibra conduce el haz de luz sobre la región de interés (zona de la hoja afectada por la enfermedad que ha de ser medida).

Figura 2-9: Disposición de los equipos de laboratorio y muestra para la medición de firmas espectrales.



Los datos espectrales capturados son almacenados en un archivo CSV, al inicio de este se encuentran los parámetros bajo los cuales fue realizada la medición espectral, después se ubican dos columnas de datos. La columna izquierda representa el rango de medición en el espectro electromagnético sensado representando un total de 750 datos capturados por muestra, en la columna derecha se encuentra la energía reflejada que ha sido capturada y transmitida por la fibra óptica hasta ser medida por el espectro fotómetro, esta se encuentra en el rango de los nW (ver Anexo C).

2.2.3 Normalización de los datos

Los valores obtenidos en el proceso de medición espectral se encuentran expresados en magnitud de energía (nW), esta magnitud de energía no representa la respuesta espectral característica del objeto sensado, para obtenerla es necesario realizar una normalización de los datos obtenidos, esto se lleva a cabo por medio de la ecuación 2.1, donde el numerador corresponde a la cantidad de energía reflejada por la muestra y el denominador la cantidad de energía reflejada por un material de referencia.

$$\text{Reflectancia relativa (R\%)} = \frac{\text{Cantidad de luz reflejada por la muestra}}{\text{Cantidad de luz reflejada por un material estándar}} \times 100 \quad (2.1)$$

En la Figura 2-10 se puede observar el material de referencia utilizado para esta investigación, que corresponde a un blanco de referencia cubierto de sulfato de bario el cual produce una superficie de reflectancia difusa perfecta, con una efectividad mayor al 98% en el rango de 300 a 2400nm como lo establece el fabricante *Labsphere* (*Labsphere*, 2010).

Figura 2-10: Material de referencia.



2.3 Firmas espectrales

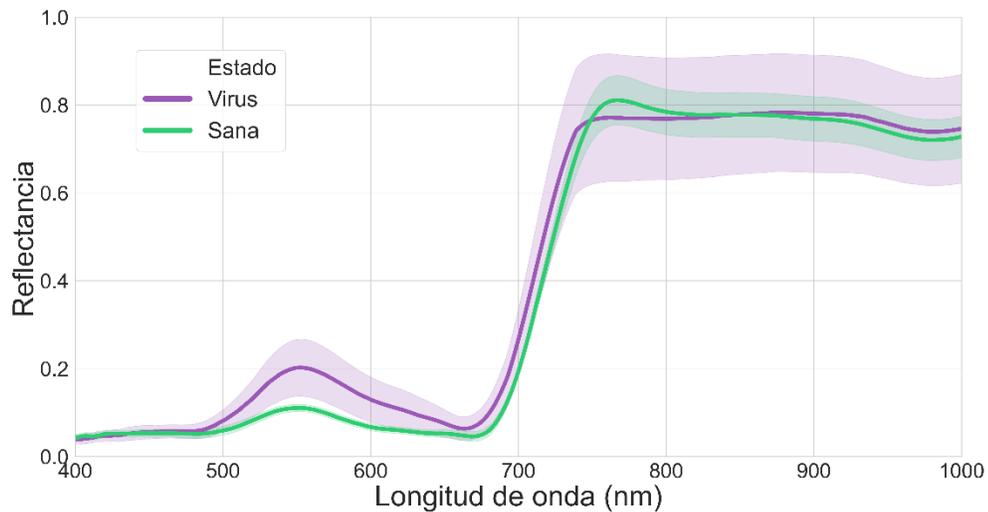
En el proceso de lectura espectroscópica se recolectaron de hojas de crisantemo pertenecientes a tres variedades (*Anastasia White*, *Margarita White* y *Anastasia Dark Green*), cada una con presencia de los cuatro posibles estados de interés para este trabajo (hoja sana, afectada por virus, afectada por trips y afectada por ácaros), finalmente fueron recolectadas 15 muestras para cada uno de estos estados dando así un total de 180 muestras.

A continuación, se presentan los resultados del análisis de las firmas espectrales correspondientes a los problemas fitosanitarios de interés para este trabajo (ácaros, trips y virus), en comparación directa con muestras sanas, donde cada línea del gráfico representa la reflectancia promedio y la zona sombreada la desviación estándar de esta población.

En la Figura 2-11 se presenta la curva comparativa entre la respuesta espectral de hojas de crisantemo sanas y con presencia de Virus del marchitamiento moteado del tomate. Esta figura se presenta en el rango de los 400-1000 nm del espectro electromagnético y una magnitud de 0 a 1 de reflectancia. En la parte central del componente verde, alrededor de los 550 nm se puede observar una diferencia de aproximadamente el 45% de la reflectancia entre la media de ambas muestras, por otro lado, en la pendiente ubicada entre los 700 a 800 nm esta diferencia es cerca del 4.7% en su punto máximo después de la zona de absorción de la clorofila. Igualmente se evidencia una diferencia significativa entre el comportamiento de la desviación estándar en ambos

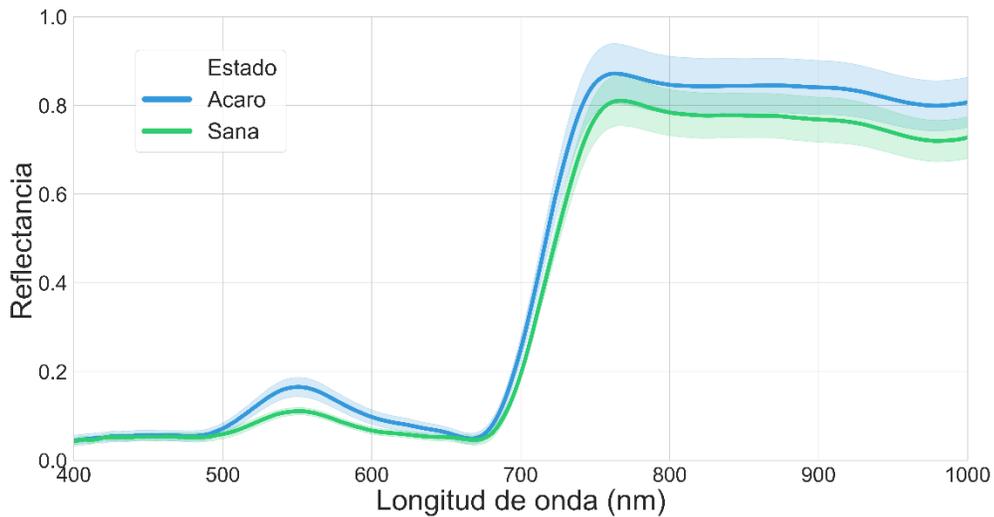
grupos, presentando las muestras de virus una mayor variación, esto es posiblemente atribuible a la amplia variabilidad de esta enfermedad en las hojas de crisantemo, dónde su manifestación va desde leves amarillamientos, pasando por amarillamientos pronunciados hasta el necrosamiento de las hojas; lo que resulta en una alta variabilidad en la respuesta espectral. Considerando la manifestación de estos síntomas se puede concluir que, en un grupo de muestras con tejido vegetal sano se encontrará un comportamiento más estable en cuanto a la energía reflejada, mientras aquellas con sintomatología de virus presentarán un aumento o disminución en su reflectancia, y este comportamiento fluctúa de acuerdo con los niveles de manifestación de la enfermedad.

Figura 2-11: Respuesta espectral de hojas de crisantemo sanas y con presencia de Virus del marchitamiento moteado del tomate.



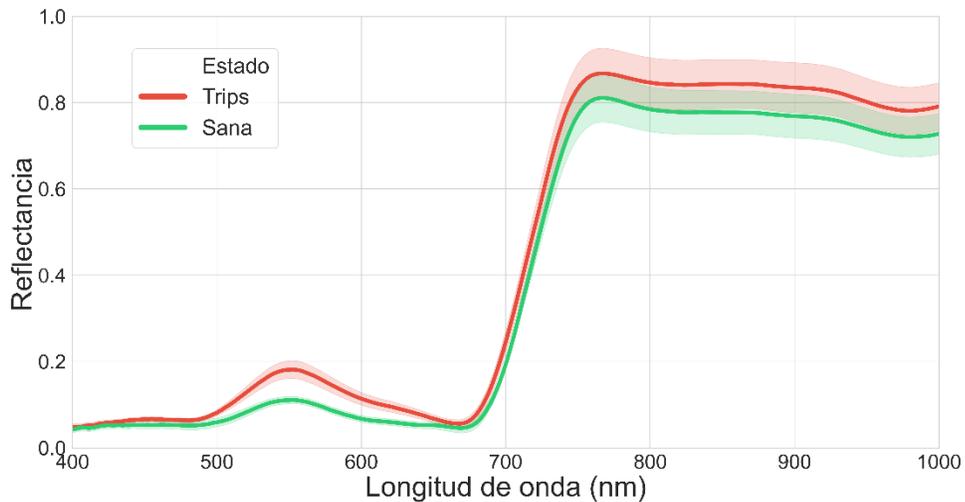
Igualmente, en la Figura 2-12 se presenta una comparativa entre las respuestas espectrales de hojas de crisantemo tanto sanas como afectadas por ácaros. Aunque se presenta un comportamiento similar al observado con anterioridad para virus, en este caso la diferencia en la magnitud de las señales en la región de los 550 nm es de alrededor del 33% de la reflectancia entre las medias. Por otra parte, en la región del infrarrojo cercano, es difícil separar las muestras debido al solapamiento dado por su variabilidad espectral.

Figura 2-12: Respuesta espectral de hojas de crisantemo sanas y con presencia de ácaros.



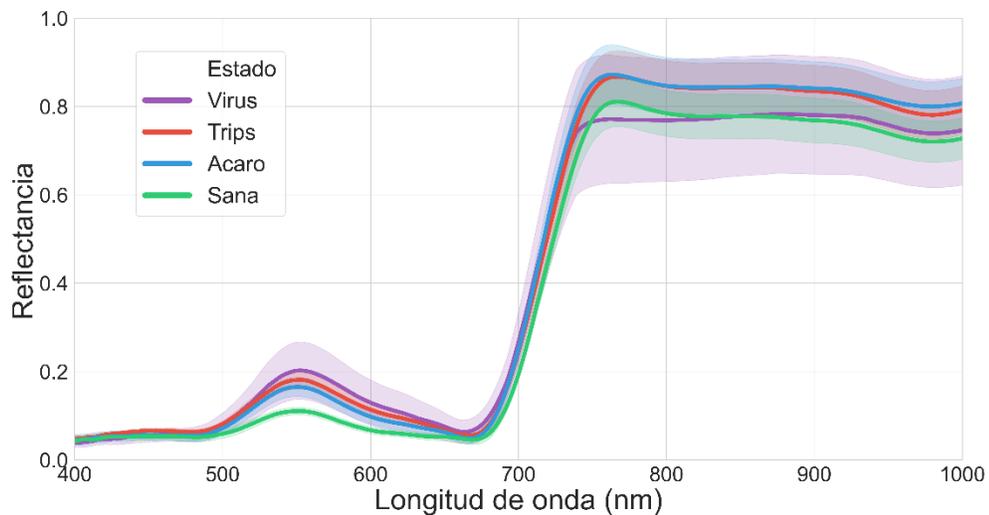
Por otra parte, en la Figura 2-13 se presenta la respuesta espectral de hojas sanas versus aquellas afectadas por trips, de igual manera se presenta un comportamiento similar al evidenciado en casos anteriores cerca de los 550 nm, con una diferencia en magnitud de alrededor del 39% de la reflectancia entre las medias, por el contrario en la zona del infrarrojo cercano, el comportamiento se asemeja al observado en el caso de ácaros, dónde esta zona presenta poco potencial discriminante dada la similitud en su comportamiento espectral.

Figura 2-13: Respuesta espectral de hojas de crisantemo sanas y con presencia de trips.



Finalmente, en la Figura 2-14 se pueden observar simultáneamente las respuestas espectrales de hojas de crisantemo tanto sanas como afectadas por las enfermedades de interés, en esta se presenta nuevamente que la región espectral ubicada entre los 500-600 nm, es una zona de interés y con potencial discriminante entre tejido sano y aquel con manifestación de alguno de los problemas fitosanitarios en estudio, igualmente la zona del infrarrojo cercano a partir de los 700 nm puede presentar carácter discriminatorio entre alguna de las enfermedades, de esta manera se considera que las tres enfermedades evaluadas presentan potencial espectral discriminatorio para ser evaluadas posteriormente por medio de un sistema espectral basado en imágenes dónde se cuenta tanto con información espectral como espacial que idealmente permita diferenciarlas.

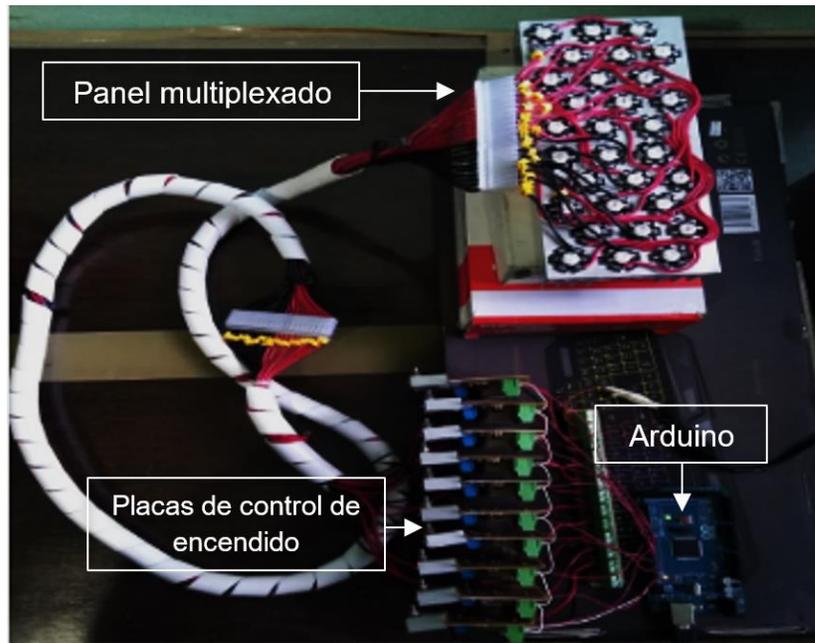
Figura 2-14: Respuesta espectral de hojas de crisantemo sanas, con presencia de ácaros, Virus del marchitamiento moteado del tomate y trips.



3.Optimización de un prototipo de laboratorio para la captura de imágenes espectrales

A continuación, se describen los procedimientos, técnicas, actividades y demás estrategias metodológicas utilizadas durante la investigación e igualmente los resultados obtenidos en cuanto la optimización de un prototipo básico de laboratorio para la captura de imágenes espectrales, dónde se presenta la caracterización de los diferentes LEDs que componen el sistema de iluminación, así como la estabilidad de emisión de estos, e igualmente la calibración y configuración de la cámara implementada en el sistema de captura.

El sistema de iluminación espectral se basa en un prototipo desarrollado para el laboratorio de Visión artificial y Fotónica, por estudiantes de ingeniería mecatrónica del ITM como resultado de su trabajo de grado (Gómez Granda et al., 2018). Este sistema consta de tres paneles multiplexados cada uno con 3 LEDs para cada una de las 10 longitudes de onda que lo constituyen, adicional a esto se cuenta con una rueda de LEDs infrarrojos para ser dispuesta directamente sobre la cámara. El encendido es controlado por medio de una orden enviada a un Arduino Mega vía puerto serial, esta contiene un código que determina el led perteneciente a la longitud de onda deseada, después se envía un pulso PWM a las placas de control de encendido, permitiendo el paso tensión para encender los LEDs deseados (ver Figura 3-1). Las longitudes de onda de los LEDs utilizados dependieron de la disponibilidad con la que se contaba en el mercado, estas son presentadas en la Tabla 3-1.

Figura 3-1: Ejemplo de panel de iluminación espectral (Gómez Granda et al., 2018).**Tabla 3-1:** Longitudes de onda disponibles en el sistema de iluminación

Nombre	Longitud de onda (nm)
Ultravioleta	405
Violeta	430
Azul	460
Cian	495
Verde	516
Chartreuse	551
Amarillo	595
Rojo	618
Rojo profundo	637
Infrarrojo	728
Infrarrojo2	850

3.1 Caracterización del sistema de iluminación LED

Con el objetivo de garantizar la estabilidad y comportamiento del sistema de iluminación, cada uno de los LEDs fue caracterizado medición su firma espectral correspondiente, para esto se utilizaron los mismos equipos y procedimiento con los cuales se realizó la medición de las firmas espectrales en el objetivo 1 (espectrofotómetro, fibra óptica y blanco de referencia).

3.1.1 Protocolo de medición

Para la configuración de lectura de las firmas espectrales de cada led se definieron como parámetros: la resolución de medida del equipo (*Resolution*), el modo sentido (*Sense mode*) que determina la sensibilidad del espectrofotómetro, la cantidad de mediciones realizadas (*Average times*) a la señal para mejorar la relación señal ruido, el intervalo de muestreo (*Sampling interval*) y la distancia del led a la fibra óptica.

Tabla 3-2: Configuración definida para la medición de las firmas espectrales correspondientes a cada led en el sistema de iluminación.

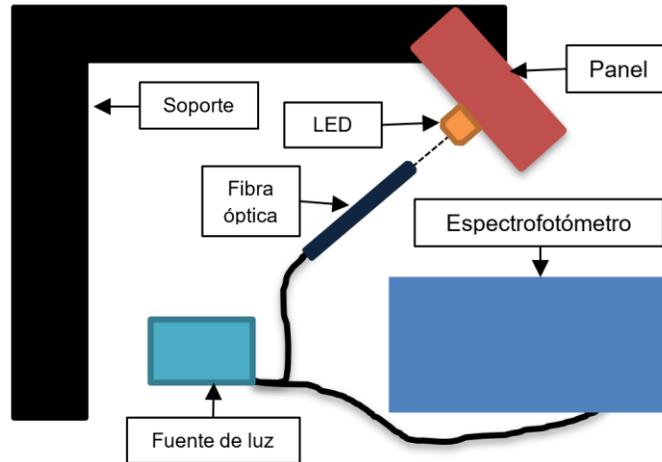
Parámetros	Configuración
<i>Resolution (nm)</i>	5.0
<i>Sense mode</i>	HIGH2
<i>Average times</i>	4
<i>Sampling Interval (nm)</i>	0.5
Distancia (mm)	10

3.1.2 Lectura de datos espectrales para los LEDs

Para el procedimiento de lectura de las firmas espectrales inicialmente el espectrofotómetro fue ubicado sobre una mesa con el objetivo de garantizar su estabilidad, posteriormente se seleccionó uno de los paneles al extremo del soporte vertical, se conectó la fibra óptica a la fuente de luz y el espectrofotómetro, finalmente la fibra óptica fue posicionada de manera diagonal a un ángulo de 45 grados y una distancia de 10 mm del LED a sensar (ver Figura 3-2). El proceso de medición fue realizado en un cuarto de paredes oscuras a puerta cerrada garantizando la no presencia de alguna

otra fuente iluminación natural o artificial que pudiera afectar el proceso, todo esto se realizó para cada una de las 11 diferentes longitudes de onda que se encuentran en el sistema de iluminación.

Figura 3-2: Procedimiento de medición espectral de LEDs.



3.1.3 Procesamiento y análisis de los datos

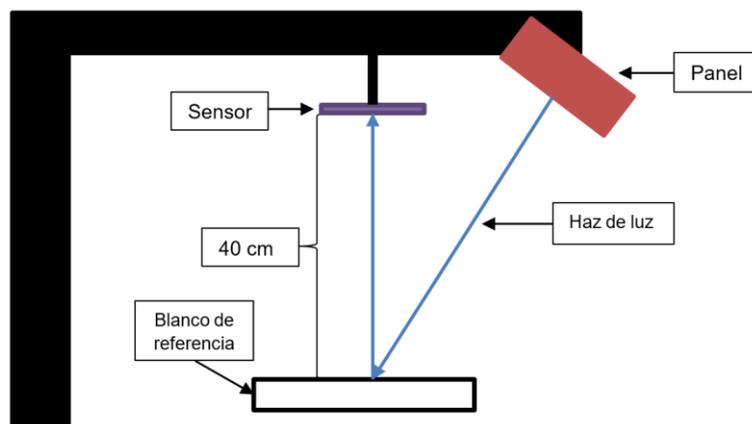
El procedimiento de procesamiento de las firmas espectrales fue el mismo empleado en el capítulo anterior para el objetivo 1, de tal manera que los datos obtenidos se normalizaron con su correspondiente blanco de referencia y finalmente su magnitud fue escalada a un valor de 0 a 1 siguiendo la ecuación 3.1, donde se toman los valores mínimo y máximo para escalar cada uno de los valores y de esta manera observar el comportamiento espectral de cada LED sin importar la magnitud de energía emitida por este.

$$x.escalada = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

3.1.4 Evaluación de la estabilidad de la emisión de los LEDs

Una vez realizada la caracterización espectral de cada LED, se valuó la estabilidad de emisión de estos determinando la cantidad de energía medida en lúmenes que llegaría a la cámara, esto fue realizado por medio de un sensor ubicado a 40 cm del blanco de referencia, este último fue extraído de la cubierta de un escáner comercial que hacía parte de una impresora Epson Stylus tx125 (ver Figura 3-3).

Figura 3-3: Disposición del montaje para medición de estabilidad del sistema de iluminación.



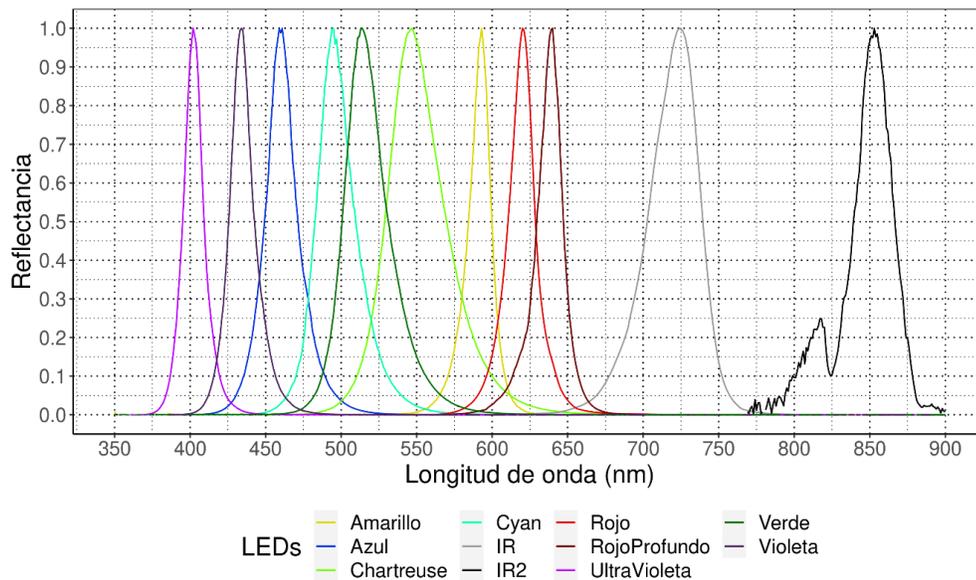
3.1.5 Caracterización del sistema de iluminación LED

En la Figura 3-4 se presenta el comportamiento espectral de cada uno de los LEDs que componen el sistema de iluminación en una escala de 0 a 1, en el caso del ultravioleta que inicialmente era denominado por el fabricante con una longitud de onda de unos 405 nm se observa un pico de emisión en los 400 nm con un ancho de alrededor de 50 nm iniciando en los 375 y hasta los 430 nm, siguiente se encuentra el violeta indicado por el fabricante con una longitud de onda de 430 nm que concuerda con el pico que se presenta en la firma espectral, con un comportamiento que va desde los 400 hasta los 475 nm aproximadamente, el azul presentado en los 460 nm concuerda con el pico de la señal que se observa presentándose a partir de los 475 hasta los 525 nm, a continuación se encuentra el cian que de igual manera concuerda el valor presentado inicialmente por el fabricante con lo observado en los 495 nm presentándose desde los 450 hasta los 575 nm, similarmente el verde presenta su pico en los 416 nm iniciando en los 475 hasta los 600 nm, de manera diferente el chartreuse inicialmente considerado en los 551 nm presenta un pico alrededor de los 548 nm con un ancho ligeramente mayor iniciando en los 480 hasta los 625 nm, en el caso

del amarillo, este presenta un ancho de cobertura menor que va desde los 550 nm hasta los 625 nm con un pico consistente con lo presentado por el fabricante en los 595 nm, el led rojo es consistente con el fabricante con un pico en los 618 nm cubriendo desde los 575 hasta los 650 nm, cercano a este se encuentra el rojo profundo con un pico en los 637 nm partiendo desde los 600 hasta los 650 nm, después se encuentran los LEDs con presencia en el infrarrojo, en regiones más separadas a comparación del resto, el primero ligeramente diferente de lo presentado por el fabricante inicialmente en los 728 nm, pero se observa que es más cercano a los 725 nm partiendo desde los 650 hasta los 775 nm, finalmente el segundo presenta con un pico en los 850 nm, con una cobertura más amplia desde 775 hasta los 900 nm.

Según lo observado, solo se presentan ligeras variaciones con los datos proporcionados por el fabricante, las cuales se encuentran dentro un rango efectivo de aproximadamente 125 a 150 nm para cada uno de los LEDs. Finalmente, ninguno se superpone significativamente con otro lo cual garantiza espectral en el sistema.

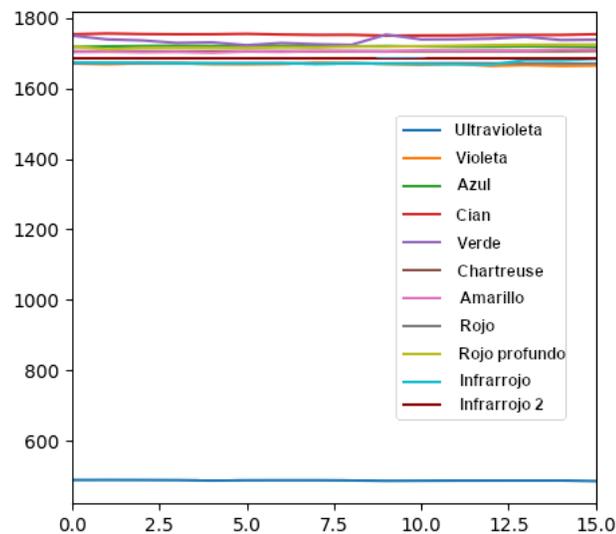
Figura 3-4: Comportamiento espectral de cada uno de los LEDs que conforman el sistema de iluminación.



Por otra parte, en la Figura 3-5 se presentan los resultados obtenidos al evaluar la estabilidad de los LEDs, esta fue determinada al exponer cada espectro reflejado por el blanco de referencia

durante 15 s a un sensor de lúmenes, capturando la magnitud de energía que sería capturada por la cámara. Se observa que en su gran mayoría hay estabilidad en las señales censadas, presentándose algunas variaciones en el caso del LED verde (416 nm) y una menor magnitud de la señal emitida por el LED ultravioleta (400 nm), lo cual se debe a la dificultad que presenta el sensor de capturar energía en este espectro, finalmente se permite determinar una garantía de estabilidad del sistema de iluminación con el objetivo de determinar los parámetros de captura de las imágenes espectrales.

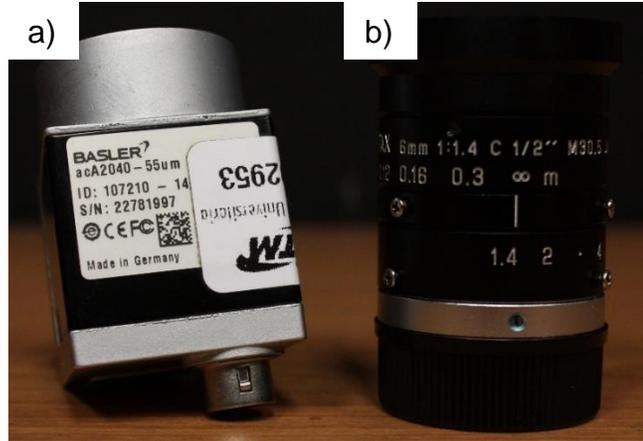
Figura 3-5: Comparativa de estabilidad de emisión del sistema de iluminación.



3.2 Configuración y calibración del sistema de adquisición

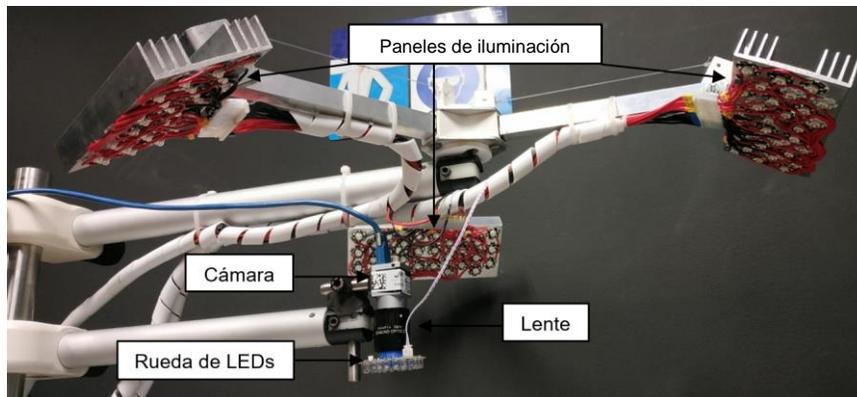
Para el proceso de captura de imágenes espectrales se incorporó una cámara monocromática Basler acA2040 - 55um (Figura 3-6-a) al sistema de iluminación, esta cuenta con un sensor Sony IMX2658LLR-C CMOS, una resolución máxima de 2064 x 1544 píxeles, un máximo de 55 FPS, capacidad de almacenamiento de imágenes de 8 y 12 bits en formatos TIFF, RAW y PNG (Ag, 2015), acompañada de un lente Pentax (ver Figura 3-6-b) que cuenta con una apertura focal de 6.0 mm, una relación máxima de apertura de f/1.4 y una distancia focal mínima de 0.2 m.

Figura 3-6: Equipo de captura. a) cámara Basler acA2040 - 55um (ver Anexo D), b) lente Pentax.



En la Figura 3-7 se observa el montaje de la cámara junto con los tres paneles que constituyen el sistema de iluminación ubicados de manera triangular, de tal manera que estos irradian directamente la muestra. La cámara es ubicada en su centro para realizar la captura de las imágenes espectrales, y finalmente al lente de la cámara se encuentra incorporada una rueda con 38 LEDs infrarrojos que operan en los 850 nm.

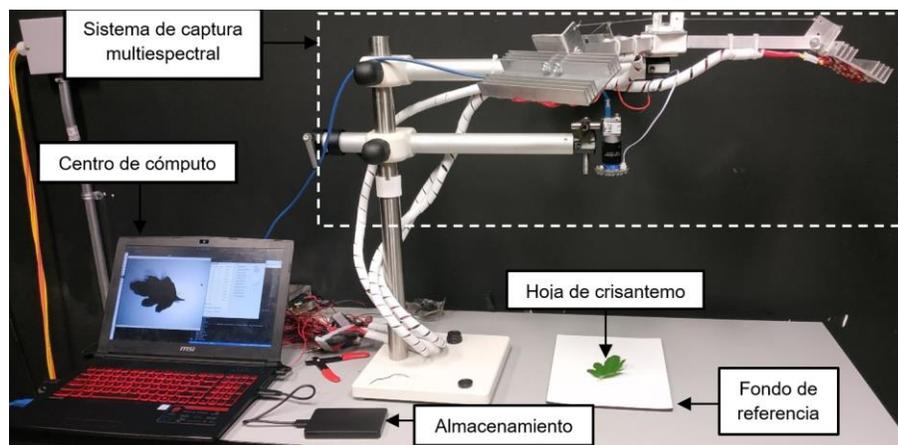
Figura 3-7: Montaje de cámara y sistema de iluminación.



Por último, en la Figura 3-8 se observa el montaje completo del sistema, el cual consta de: un centro de cómputo encargado tanto del control del de iluminación por medio de comunicación serial con el Arduino Mega, como de la operación de la cámara vía puerto USB 3.0, un fondo blanco de

referencia dónde es ubicada la hoja de crisantemo y el sistema de captura multispectral. La cámara fue ubicada a 40 cm desde el fondo blanco hasta el lente de la cámara, finalmente las imágenes capturas son almacenadas en un disco duro externo bajo formato RAW a 12 bits bajo codificación Little-endian.

Figura 3-8: Montaje completo para la captura de imágenes multispectrales en hojas de crisantemo



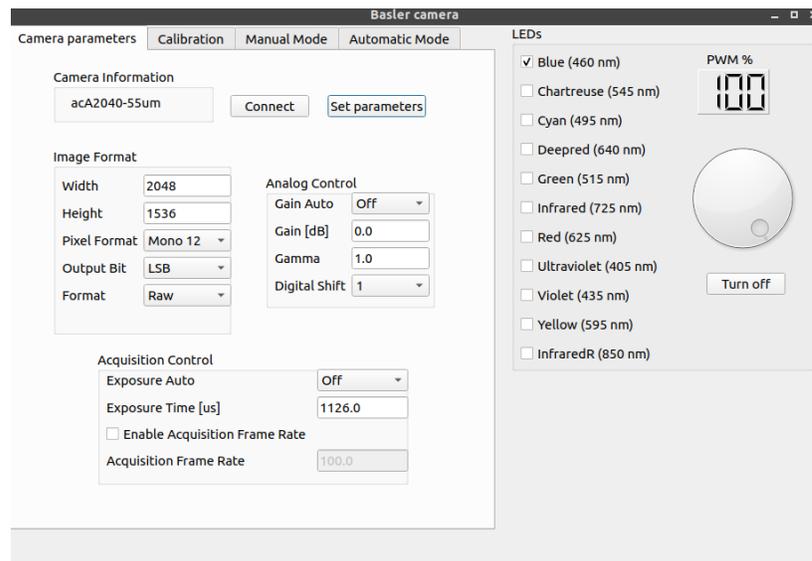
3.2.1 Configuración del sistema de adquisición (cámara)

Inicialmente, el prototipo para la captura de imágenes espectrales incorporaba una cámara monocromática JAI AD-081GE con 2 sensores CCD, pero dado que desde su configuración esta no permitió modificaciones de los parámetros de calibración para la toma de imágenes, y dispone de un sensor de menor resolución (1024 x 768 píxeles), esta fue reemplazada por una cámara monocromática Basler acA2040 - 55um.

Para su implementación, fue necesario el desarrollo desde cero de una interfaz de control que permitiera tanto configurar, calibrar y controlar la cámara como a su vez el sistema de iluminación. Esta fue desarrollada utilizando como base el lenguaje de programación Python 3.5 el cuál fue integrado con la librería pylon proporcionada por el fabricante para el control de la cámara Basler y la interfaz gráfica fue desarrollada bajo la librería PyQt 5. En la Figura 3-9 se presenta el flujo de operación de la interfaz gráfica.

Figura 3-9: Flujo de operación de la interfaz de control.

La interfaz de control consta en su izquierda, de un panel con cuatro pestañas para acceder a los diferentes modos de operación de la cámara y a su derecha un panel para el encendido manual y magnitud de intensidad (dada por medio de un pulso PWM) de los diferentes LEDs que se encuentran en el sistema de iluminación (ver Figura 3-10). La primera pestaña del panel izquierdo permite conectar la cámara y seleccionar sus parámetros de operación tales como: ancho y alto de la imagen, formato de almacenamiento (8 o 12 bits), bit de salida (LSB o MSB), formato del archivo (TIFF, PNG, RAW), control de ganancia y exposición, una vez seleccionados basta con presionar el botón *Set parameters* para aplicar la configuración a la cámara y continuar con el proceso de captura (ver Figura 3-10).

Figura 3-10: Panel inicial en la interfaz de control del sistema de captura espectral.

Con la finalidad de garantizar que no se presente sobre exposición al momento de iluminar la muestra, fue necesario determinar el tiempo de exposición adecuado para cada longitud de onda que se encuentra en el sistema de iluminación, para este proceso fue diseñada la pestaña de calibración que se observa en la Figura 3-11 dónde se requiere definir como constantes el valor de referencia (*set point*) y la ganancia de la cámara. Este procedimiento es realizado con una captura de video en tiempo real del blanco de referencia que es usado como fondo en la imagen, en este caso el valor de intensidad máximo que puede presentarse en una imagen de 12 bits es de 4095, por lo tanto y para evitar sobre exposición en la captura, se determinó un valor de intensidad en niveles de gris de 1606 como referencia, lo que corresponde a un 40%.

Una vez definidos los parámetros se le indica al programa que inicie el proceso de calibración, este comenzará a procesar la imagen en tiempo real y calcular el promedio de niveles de intensidad en el área capturada, de tal manera que el tiempo de exposición aumente o reduzca dependiendo de cuán cerca se encuentre este al valor de referencia, en una ventana emergente se puede observar un histograma correspondiente a los niveles de intensidad presentes en la imagen de tal manera que le permita al usuario dar seguimiento al proceso de calibración (ver Figura 3-12). Una vez el promedio de niveles de intensidad en la imagen capturada sea igual al valor de referencia, el programa se detiene y se da como resultado el tiempo de exposición correspondiente. Este

procedimiento de calibración fue realizado al inicio de cada sesión de captura para cada una de las 11 longitudes de onda presentes en el sistema de iluminación, garantizando la no presencia ya sea de fuentes de luz naturales o artificiales que pudieran afectarlo.

Figura 3-11: Pestaña de calibración de exposición

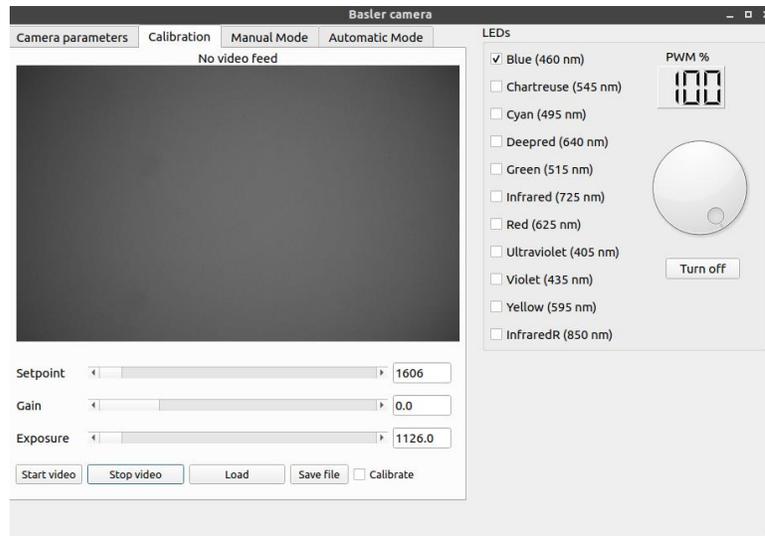
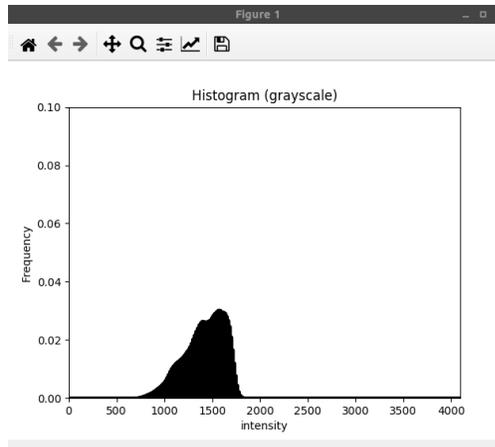
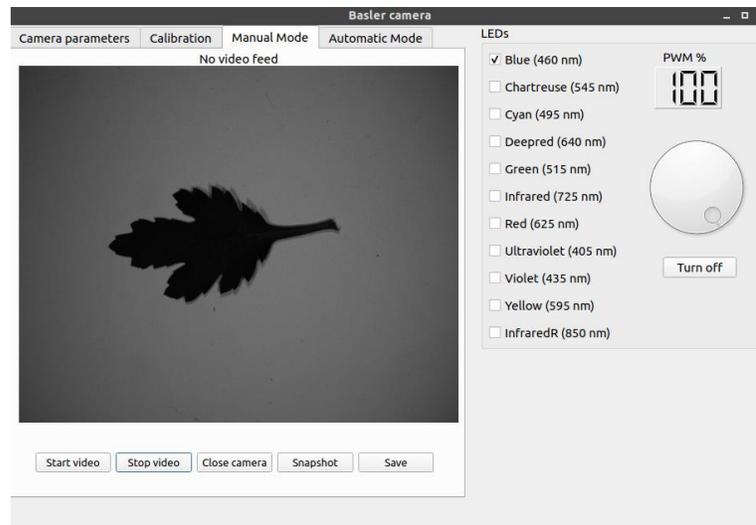


Figura 3-12: Ventana emergente para la visualización del histograma en el proceso de calibración.

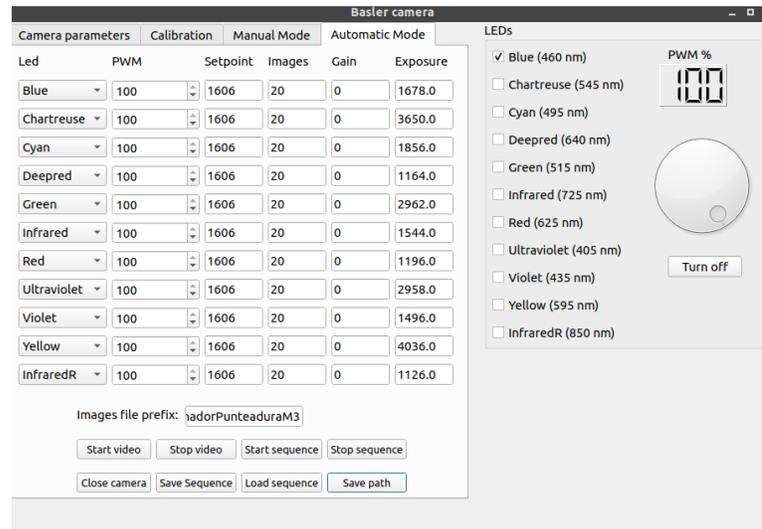


La pestaña de modo manual (*manual mode*) permite observar en tiempo real la imagen capturada por la cámara, ya sea para verificar el estado de la adquisición, la ubicación de la muestra dentro en el campo visual de la cámara o realizar pruebas en tiempo real (ver Figura 3-13).

Figura 3-13: Pestaña de modo manual para la previsualización de la imagen capturada por la cámara.



Finalmente, se encuentra pestaña de modo automático (*automatic mode*) el cuál es utilizado para generar una secuencia de captura de las muestras, en los menús desplegables ubicados a la izquierda se deben los LEDs que serán utilizados, a su derecha se define la magnitud del pulso PWM que determina su intensidad lumínica, después puede ingresarse el valor de referencia deseado, seguido se debe definir la cantidad de imágenes que serán capturadas para cada LED, la ganancia es definida por defecto con un valor de 0 y finalmente se debe ingresar el tiempo de exposición calculado para cada espectro al inicio de la sesión (ver Figura 3-14).

Figura 3-14: Panel de modo automático para la captura de imágenes.

Cuando se han ingresado todos los parámetros se define la ruta de almacenamiento para las imágenes y se inicia la secuencia de captura previamente definida, para esto se da una espera de 5 s con el LED encendido para garantizar la estabilidad en la radiación de la muestra antes de almacenar las imágenes, este procedimiento es realizado para cada una de las hojas de crisantemo que han de ser capturadas.

4. Metodología para la detección de enfermedades

A continuación, se describen los procedimientos, técnicas, actividades y demás estrategias metodológicas utilizadas durante la investigación e igualmente los resultados correspondientes a la metodología desarrollada para la detección de enfermedades en plantas de crisantemo a partir de imágenes espectrales. Este procedimiento se da en dos pasos: el primero es la generación de imágenes de reflectancia a partir de las imágenes adquiridas con el sistema de captura multiespectral, el segundo es la identificación de enfermedades, dónde se abarcan los resultados obtenidos para las tres enfermedades de interés que se evalúan en este trabajo.

Una vez adquiridas las imágenes multiespectrales de hojas de crisantemo con presencia de las enfermedades de interés, se procede a la generación de imágenes de reflectancia con corrección de no uniformidad espacial para cada longitud de onda, con estas se genera un cubo de datos multiespectral.

4.1 Procedimiento para la generación de imágenes de reflectancia

En la Figura 4-1 se presenta el procedimiento realizado para la generación de las imágenes de reflectancia, el primer paso es la captura de 20 imágenes espectrales en cada uno de los 11 presentes en el sistema de iluminación, resultando en un total de 220 imágenes para cada hoja que es capturada. Después, se crea una imagen promedio de esas 20 capturadas para cada uno de los canales con la finalidad de reducir la posible presencia de ruido generado en la captura y así tener una imagen fiable.

Figura 4-1: Procedimiento para la generación de imágenes de reflectancia.

En el 5 paso es realizada una corrección de no uniformidad de iluminación, esta es calculada siguiendo un algoritmo lineal que se basa en el cálculo de matrices de ganancia y offset (ecuación 4.1):

$$I_c(i, j) = O(i, j) + G(i, j)I(i, j)$$

$$G(i, j) = \frac{\bar{I}_B - \bar{I}_{osc}}{I_B(i, j) - I_{osc}(i, j)} \quad (4.1)$$

$$O(i, j) = \bar{I}_{osc} + G(i, j)I_{osc}(i, j)$$

Dónde $O(i, j)$ representa el elemento (i, j) de la matriz offset, $G(i, j)$ el de la matriz ganancia, y \bar{I}_{osc} y \bar{I}_B son los niveles de intensidad de referencia de la imagen oscura y de la imagen base (Aikens et al., 2008). Finalmente, la imagen espectral es generada en el paso 6, en esta cada canal es combinado siguiendo la ecuación lineal 4.2:

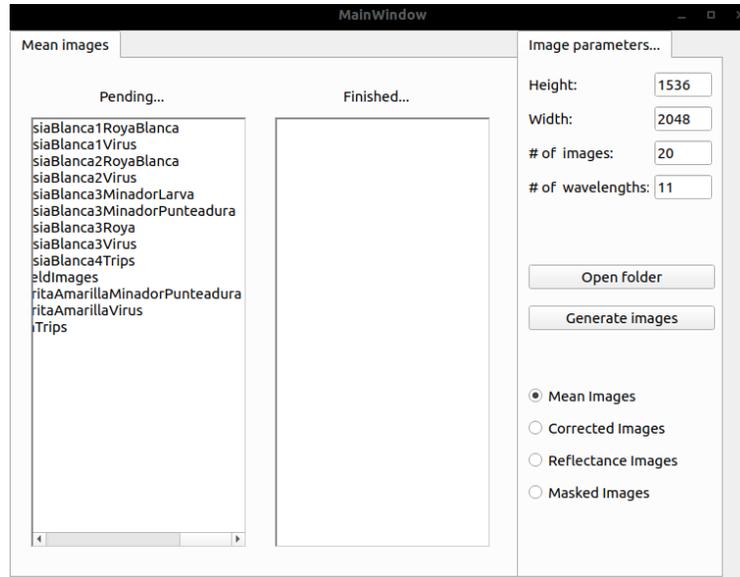
$$I_{Rfl}(i, j) = r_\lambda \frac{I(i, j) - I_{Dark}(i, j)}{I_W(i, j) - I_{Dark}(i, j)} \quad (4.2)$$

Correspondiendo $I_{Rfl}(i, j)$ a la imagen de reflectancia espectral corregida en una longitud de onda en específico, el factor $I_W(i, j)$ representa la reflectancia del blanco de referencia para dicha longitud de onda, $I_{Dark}(i, j)$ es la imagen de campo oscuro, y $I(i, j)$ es la imagen corregida de la hoja de crisantemo para esa longitud de onda en específico. Como resultado final, en el paso 6 se genera un cubo de datos multiespectrales de dimensiones 2048x1536x11 por cada hoja de crisantemo que es capturada.

4.2 Generación de imágenes de reflectancia

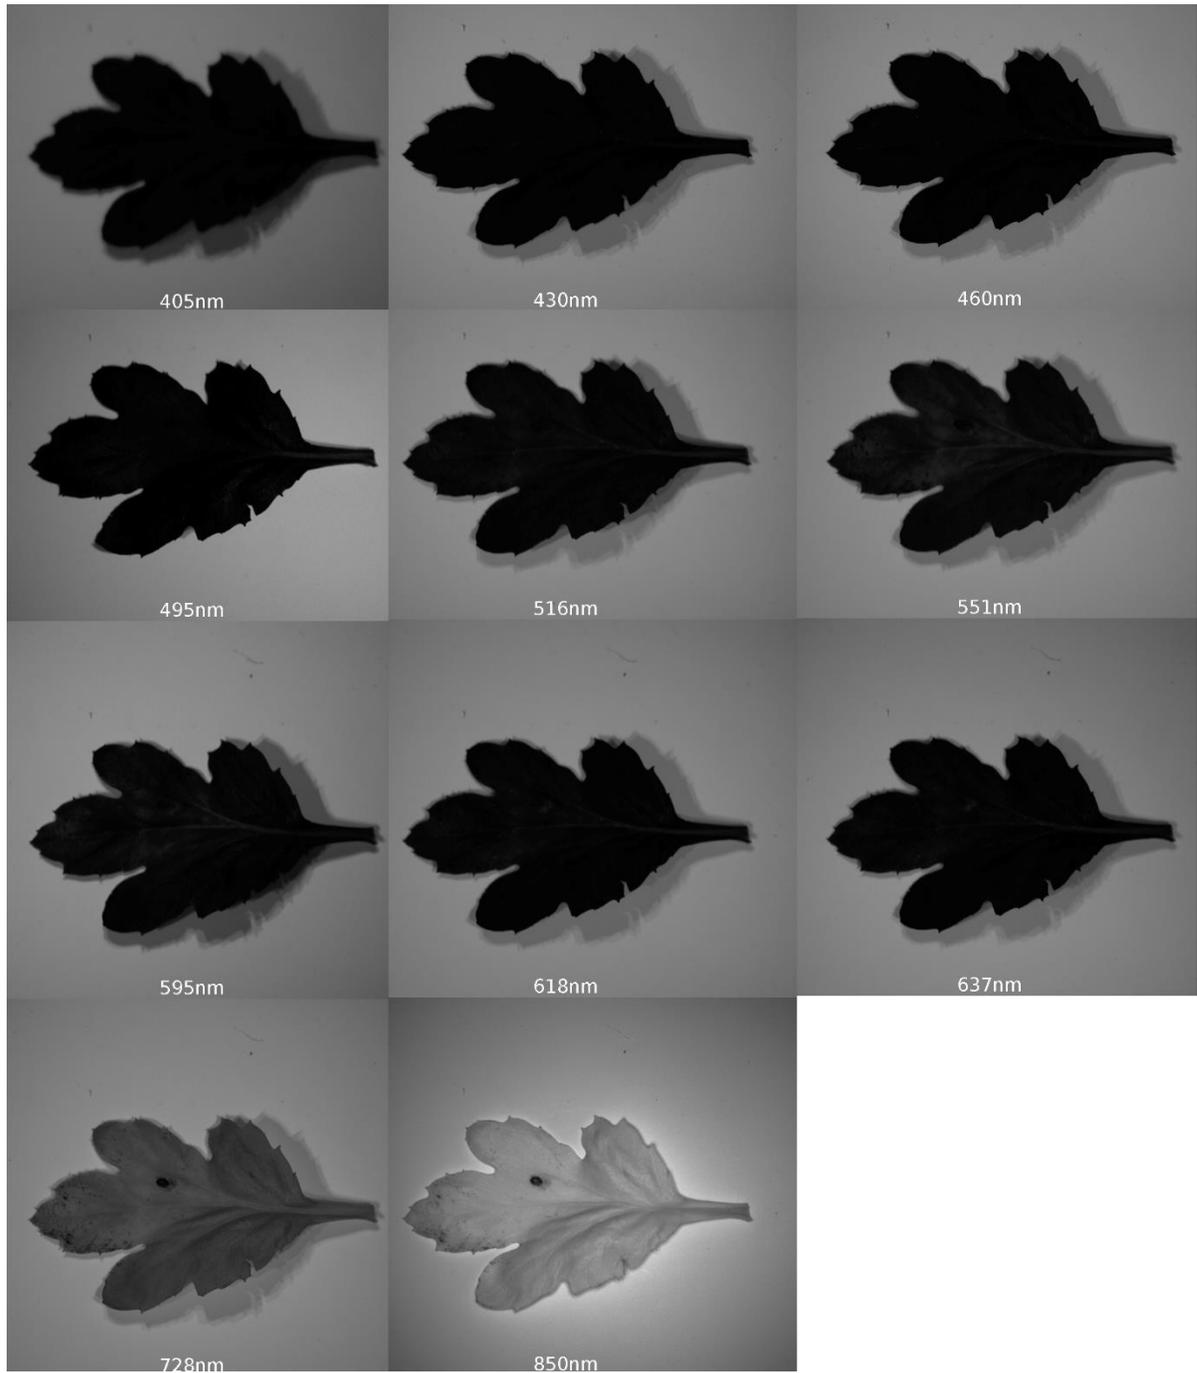
Para la generación de imágenes de reflectancia a partir de las imágenes RAW capturadas se desarrolló una interfaz gráfica por medio del lenguaje de programación Python 3.5 y la librería PyQt5, con la finalidad de facilitar este proceso. Como se observa en la Figura 4-2 esta cuenta con tres pestañas, en la primera (*pending*) son cargadas las rutas a las diferentes carpetas dónde se encuentran las imágenes RAW por medio del botón *open folder* y en la lista es seleccionada la carpeta que desea ser procesada, en la tercera (*image parameters*) se deben ingresar los parámetros de la imagen como lo son: alto, ancho, cantidad de imágenes y la cantidad de canales. En la parte inferior derecha se debe seleccionar la operación a realizar (imagen promedio, imagen corregida, imagen de reflectancia e incluso la extracción del fondo de la imagen de reflectancia), y para finalizar se presiona botón *generate images*, una vez finalizado el proceso la ruta seleccionada es eliminada panel izquierdo y agregada la pestaña central (*finished*),

Figura 4-2: Interfaz gráfica para la generación de imágenes de reflectancia a partir de imágenes RAW.



En la Figura 4-3 se puede observar el resultado final para la captura de una hoja de crisantemo con presencia de virus, allí se encuentran las imágenes de reflectancia para las 11 diferentes longitudes de onda bajo las que se realizó la captura. Se puede observar ligeramente el cambio que se da en el comportamiento espectral de la hoja, un ejemplo de esto es la alta reflectancia que presenta el tejido vegetal en las longitudes de onda del infrarrojo cercano (728 y 850 nm) el cuál es un comportamiento natural de su estructura biológica, por el contrario en regiones cercanas al verde (551 y 595 nm) se presentan ligeras cambios de coloración en parte de la hoja, mientras que en longitudes de onda más bajas (405 y 430 nm) que corresponden a regiones cercanas al ultravioleta, se presenta una baja reflectancia dado que la gran mayoría de la energía es absorbida por el tejido vegetal.

Figura 4-3: Imágenes de reflectancia para una hoja de crisantemo iluminada bajo 11 diferentes longitudes de onda

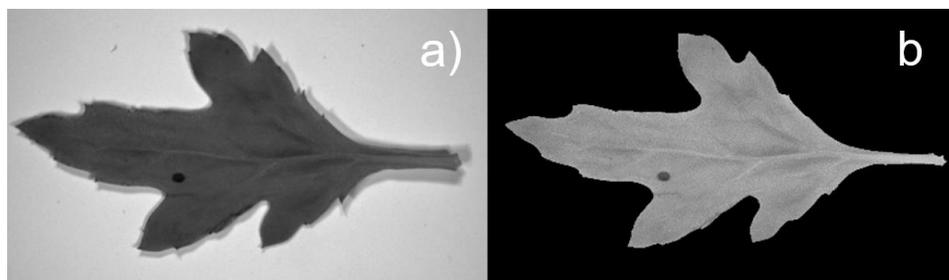


4.3 Identificación de enfermedades

Una vez obtenido el cubo de datos multiespectral de 11 canales, se procede con el procesamiento de la imagen, en primera instancia se elimina el fondo de la imagen con el objetivo de aislar el tejido vegetal, para esto se tomó las imágenes base y de hoja de crisantemo correspondientes al canal del violeta (430 nm) y se substrajo la imagen hoja de crisantemo de la imagen base, es resultado es una imagen en escala de grises dónde se diferencian el tejido vegetal, sombras y secciones correspondientes al fondo de la imagen, después de crear una máscara binaria aplicando un operador umbral a esta imagen, esa es multiplicada por la imagen original con la hoja de crisantemo.

En la Figura 4-4a se observa una imagen espectral de una hoja de crisantemo capturada en una longitud de onda de 434 nm, por otro lado, en la Figura 4-4b han sido eliminados el fondo y las sombras generadas por la distribución espacial del sistema de iluminación en esta imagen. Este proceso es aplicado a cada canal presente en el cubo de datos multiespectrales para cada muestra que ha sido capturada. El buen resultado del proceso se da ya que, en la longitud de onda de 434 nm, el tejido vegetal absorbe gran cantidad de la energía emitida por el sistema de iluminación, lo que genera un contraste significativo entre las diferentes regiones presentes en la imagen (tejido vegetal, fondo, sombras) logrando asignar fácilmente un nivel de intensidad de 0 a aquellas zonas que no son tejido vegetal.

Figura 4-4: Hoja de crisantemo. a) imagen de reflectancia original, b) imagen procesada para la eliminación del fondo y sombras generadas en el contorno la hoja.



Después, se procede a la identificación de las regiones de interés del tejido vegetal, entiéndase estas como aquellas regiones de la imagen dónde se presenta sintomatología de las enfermedades

estudiadas, esto es realizado por medio de la combinación lineal de canales espectrales que permitan distinguir estas zonas de interés, mejor conocida en el campo de la agronomía como índices vegetales.

De esta manera, el procedimiento de selección de estos índices vegetales se realizó por medio de un trabajo conjunto con el Ingeniero Andrés Mario Cardona quién es un experto en procesos de monitoreo y detección de enfermedades tradicionales, quién para su tesis de maestría en fitosanidad titulada Evaluación de técnicas de análisis multiespectrales para el reconocimiento de problemas sanitarios en crisantemo (Cardona, 2020), da búsqueda a técnicas alternativas para el monitoreo de enfermedades en plantas de crisantemo. Estos índices son aplicados sobre los cubos de datos espectrales para cada enfermedad interés que se evalúa en este trabajo.

4.3.1 Ácaro

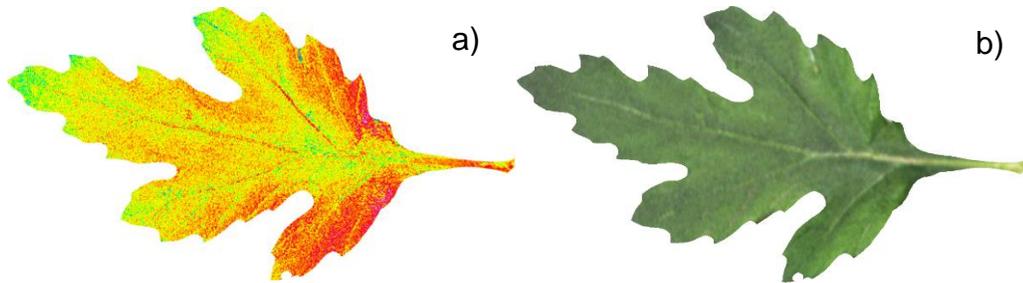
Esta enfermedad es causada por un insecto identificado como <<Araña roja>> o <<Araña amarilla>> la cual genera amarillamientos o clorosis intervenales en el haz de las hojas, esto es causado por picaduras generadas por sus pizas bucales denominadas quelíceros, estas decoloraciones tienden a ser diminutas, y a no ser que se presente un gran nivel de afección se dificulta su identificación visual. Para este caso el Ingeniero Andrés Cardona determinó en su trabajo la posibilidad de implementar el índice de relación de pigmento en la planta (PPR) (Metternicht, 2003) representado por la ecuación 4.3, donde R representa la reflectancia y los subíndices la longitud de onda a la que corresponde. En esta, son utilizadas aquellas longitudes de onda disponibles dentro del sistema espectral que más se acercan a los valores originales, correspondiendo a los valores de 551 y 460 nm respectivamente. Comparando los resultados obtenidos inicialmente en el análisis espectroscópico, éste índice involucra regiones entre los 500 y 600 nm y es allí donde la curva espectral de las hojas con ácaros presenta potencial discriminatorio con la muestra sana.

$$\frac{R_{550}-R_{450}}{R_{550}+R_{450}} \quad (4.3)$$

Al aplicar esta ecuación sobre las imágenes espectrales por medio de operaciones píxel a píxel, se obtiene una imagen en escala de grises representativa de este comportamiento espectral. Con el objetivo de separar las diferentes regiones presentes en la hoja, se asigna una escala de color

artificial a la imagen en escala de grises, dando como resultado la Figura 4-5a, mientras, en la Figura 4-5b se presenta una reconstrucción RGB de la hoja.

Figura 4-5: Hoja de crisantemo con presencia de ácaro. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.



Al evaluar cualitativamente de acuerdo con el concepto de un experto, se determinó que la información provista por este índice sobre las imágenes multiespectrales no permite una separación adecuada de las lesiones causadas por ácaros sobre las imágenes multiespectrales. Por otra parte, considerando la dificultad en la percepción visual de su sintomatología, tanto espacial como espectralmente, no se considera viable su identificación por medio de un sistema de visión artificial, considerando esto, la enfermedad no será considerada para la evaluación de algoritmos de aprendizaje.

4.3.2 Virus

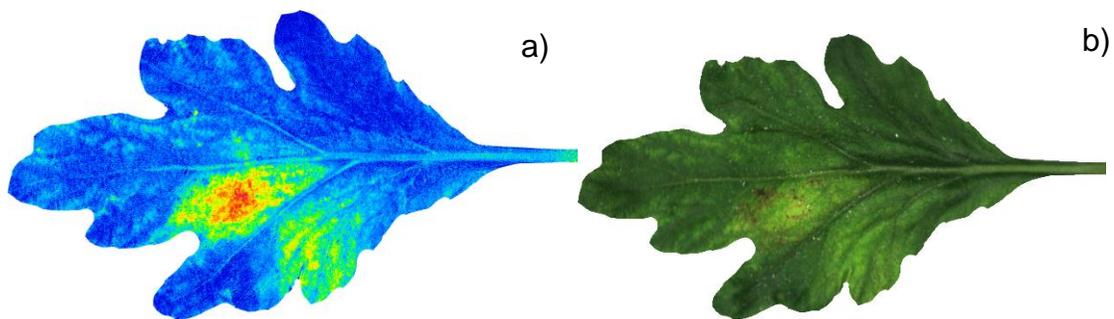
El Virus del marchitamiento moteado del tomate (TSWV) se caracteriza por la presencia de manchas o moteados cloróticos o amarillentas en las hojas y lesiones necróticas en estados avanzados. Para este caso (Cardona, 2020) plantea el uso de un índice propio para la identificación de esta sintomatología representado por la siguiente ecuación:

$$\frac{R_{625}}{R_{325}} \quad (4.4)$$

En la Figura 4-6a se presenta la imagen índice después de aplicarle una escala de color artificial, en esta los estos niveles de intensidad fueron escalados entre 0 y 4095 que corresponde a una imagen

de 12 bits. De esta manera el tejido sano es representado por niveles de intensidad entre 664 y 1650 (zonas de coloración azul oscura), las zonas de tejido vegetal con presencia de virus pueden separarse en tres niveles de severidad: baja con niveles de intensidad entre 1650 y 2000 (zonas de coloración azul clara), severidad media con niveles de intensidad entre 2000 y 3000 (zonas de coloración verde) y finalmente una severidad alta con niveles de intensidad entre 3000 y 4095 (zonas de coloración roja y naranja).

Figura 4-6: Hoja de crisantemo con presencia de virus. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.



El máximo nivel de severidad resultado de la enfermedad es el necrosamiento o muerte del tejido vegetal, que es fácilmente identificado al observar una imagen espectral correspondiente a los 850 nm (infrarrojo cercano) como se observa en la Figura 4-7. El tejido necrosado ya no refleja la energía emitida sobre la muestra, siendo visible al estar representada por niveles de intensidad menores a 500 que contrastan con el resto del tejido.

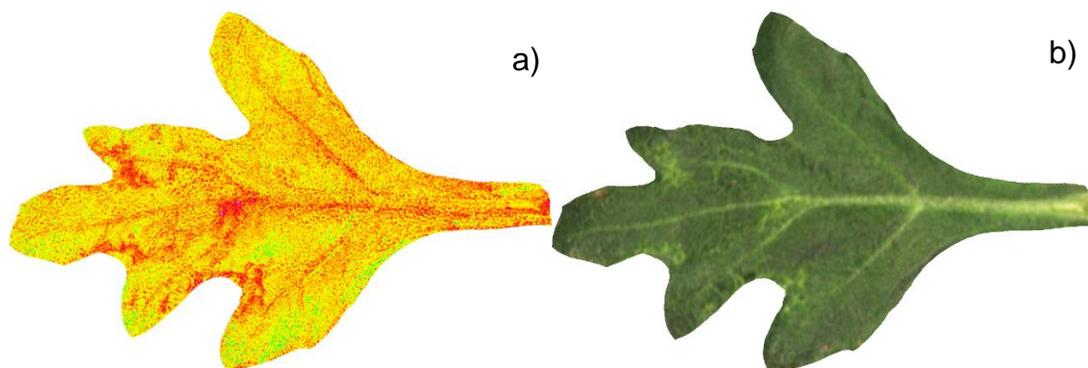
Figura 4-7: Identificación de tejido necroso en una imagen espectral correspondiente a los 850 nm.



4.3.3 Trips

El daño ocasionado por la araña de trips sobre hojas de crisantemo es caracterizado por deformaciones que parecen cicatrices o arrugas del tejido vegetal causadas por su mordedura, en este caso similar al ácaro. Para este caso, el índice PPR genera una distinción parcial entre el tejido afectado y el tejido sano, en la Figura 4-8a se observa la presencia de trips en las zonas de coloración roja (niveles de intensidad entre 3200 y 3500) que a su vez incluye regiones de la nervadura.

Figura 4-8: Hoja de crisantemo con presencia de trips. a) resultado de aplicar el índice vegetal, b) reconstrucción RGB de la hoja.



Al evaluar paralelamente los resultados obtenidos y el acercamiento que realiza el Ingeniero Agrónomo Andrés Cardona en su trabajo de maestría, es viable identificar la presencia de dos de las tres enfermedades objeto de estudio (virus del marchitamiento del tomate y trips). Considerando esto, se logra definir una metodología para la detección de estas dos enfermedades, partiendo desde la remoción del fondo de la imagen y las sombras causadas por el sistema de iluminación, seguido de la aplicación de índices vegetales para la identificación a aquellos niveles de intensidad dentro de la imagen que indican la presencia de alguna de las enfermedades de interés en la hoja.

Lo anterior simplifica el procedimiento de procesamiento de la imagen, con el fin de caracterizar estas regiones e implementar algoritmos de clasificación que permitan obtener un mejor desempeño al realizar la tarea de identificación de estas enfermedades, fin que será abordado en el siguiente capítulo.

5.Resultados de la evaluación de técnicas de clasificación

A continuación, se describen los procedimientos, técnicas, actividades y demás estrategias metodológicas utilizadas durante la investigación e igualmente los resultados correspondientes a la evaluación de técnicas de clasificación para el reconocimiento de enfermedades en plantas de crisantemo. Estos corresponden a la clasificación de Virus y Trips, en el caso de los Ácaros, previamente fue determinada su inviabilidad dada la dificultad que se presenta para la identificación visual de su sintomatología en la imagen. Para los casos evaluados, fueron utilizados modelos de aprendizaje profundo y técnicas clásicas tales como ANN y SVM.

Inicialmente, se requiere de la creación de una base de datos de imágenes multiespectrales de hojas de crisantemo con manifestación de síntomas de las enfermedades de interés. Para esto se replicó el procedimiento de recolección y transporte de material vegetal presentado en el capítulo 2.1, en las mismas fincas productoras de flores del oriente antioqueño. Estas fincas fueron visitadas en dos ocasiones durante el transcurso del año 2019, en sus etapas de alta producción, con el objetivo de contar con suficiente material vegetal para conformar la base de datos (ver Tabla 5-1):

Tabla 5-1: Información de recolección de muestras de tejido vegetal con presencia de virus y trips.

Fecha	Enfermedad	Cantidad de muestras
05/07/2019	Trips	25
	Virus	21
13/12/2019	Trips	31
	Virus	36

Cada una de las muestras recolectadas fue procesada con el sistema de captura multiespectral (presentado en el capítulo 2.2) y como resultado se obtuvieron 113 cubos de datos multiespectrales, de estos 56 imágenes multiespectrales corresponden a trips y 57 a afectaciones por virus. Toda esta información, partiendo desde la imágenes RAW originales hasta las imágenes corregidas y procesadas fueron guardas en una unidad de almacenamiento externo personal e igualmente se tiene una copia de esta información en la nube.

Considerando que la sintomatología de Virus se manifiesta a través de toda la hoja llegando a cubrir porciones significativas del área del tejido vegetal sin presentar un patrón espacial característico, mientras que la sintomatología de Trips se presenta de manera localizada con patrones específicos, se determinó que una sola estrategia de clasificación que involucrara ambas enfermedades no era óptima para la problemática presentada, por lo tanto, la tarea de clasificación de las enfermedades fue abarcada de manera individual buscando diferenciar entre tejido vegetal sano y aquel que manifestara alguna de las dos enfermedades.

5.1 Clasificación de Virus

Dada la peculiaridad presentada por esta enfermedad, donde se da, que las regiones donde se evidencia su sintomatología pueden llegar a ser píxeles individuales, se optó por realizar la clasificación de cada píxel que compone el tejido vegetal de la hoja, en lugar de regiones en específico. Con este propósito se optó por la implementación de una red profunda enfocada en la segmentación semántica, dado que su operación permite la asignación de una clase a cada píxel de manera individual, se presenta como una alternativa óptima para esta problemática. Con el objetivo de comparar este acercamiento con métodos clásicos también fueron utilizadas ANN y SVM.

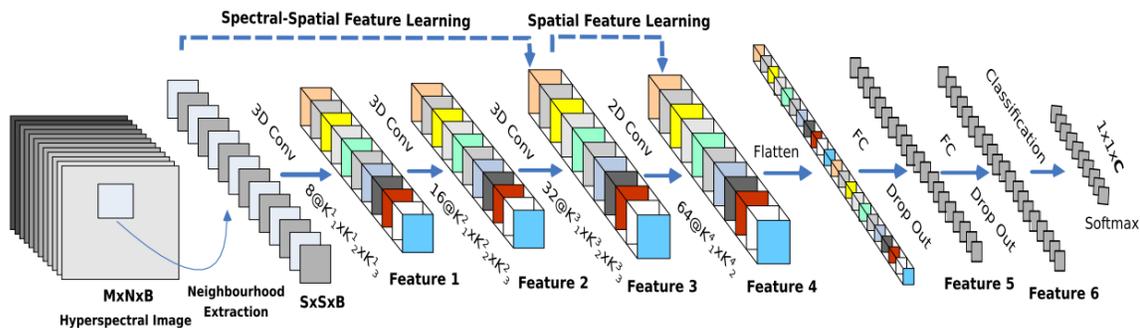
5.1.1 Segmentación semántica

Este procedimiento fue desarrollado utilizando como base el trabajo presentado por (Roy et al., 2020) donde se realiza la clasificación de imágenes hiper-espectrales pertenecientes a bases de datos de agricultura de precisión (*Indian Pines*, *University of Pavia*, y *Salinas Scene*) por medio del modelo *HybridSpectralNet* (HybridSN), en la Figura 5-1 se observa su estructura general.

En este modelo que se observa en la Figura 5-1, se utiliza un cubo de datos espectral-espacial identificado por $I \in R^{M \times N \times D}$, donde I es la entrada, M su ancho, N su alto y D es la cantidad de bandas espectrales en el cubo. Cada píxel en I presenta una clase asignada a este, creando así una matriz de tamaño $M \times N$ de etiquetas en codificación *one-hot* denominada como imagen *ground truth*. En la primera capa convolucionada 3D se aplican 8 filtros con un kernel dimensiones $3 \times 3 \times 7$ y, para la segunda capa convolucionada 3D, 16 filtros con un kernel de $3 \times 3 \times 5$ y en la última capa

convolucionada 3D se encuentran 32 filtros con un kernel de $3 \times 3 \times 3$. En cada capa convolucionada 2D se aplican 64 filtros con un kernel 3×3 , en estas cuatro capas es aplicada una función de activación *relu*, al final se cuenta con una capa *full connected* de tres capas: la primera con 256 neuronas, la siguiente con 128 neuronas ambas con una función de activación *relu*, entre estas se aplica un *dropout*, y finalmente la capa de salida cuenta con C cantidad de neuronas y una función de activación *softmax*. Dado que, este modelo fue desarrollado considerando cubos de imágenes multispectrales, antes de iniciar el proceso de aprendizaje se aplica un análisis de componentes principales (PCA) para reducir la cantidad de bandas espectrales.

Figura 5-1: Modelo de la red HybridSN propuesto por (Roy et al., 2020).

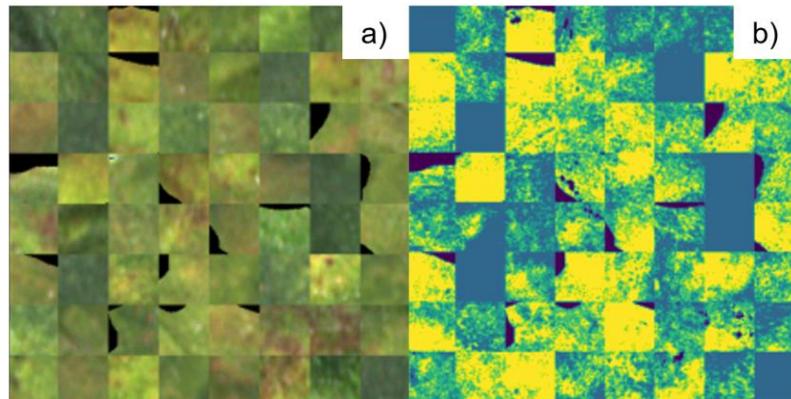


En nuestro caso no se aplicó PCA para reducir la cantidad de bandas espectrales del cubo de datos, después, dado las limitaciones de poder computacional para el entrenamiento del modelo, como entrada se usó una imagen multispectral con unas dimensiones máximas de $400 \times 400 \times 11$. Para optimizar el uso de información espacial en el entrenamiento y dado que no era posible contar con una hoja que presentara la variedad de síntomas de la enfermedad, se creó una imagen compuesta de secciones con dimensiones de $10 \times 10 \times 11$ píxeles ya fuera con presencia de tejido vegetal sano o con síntomas de Virus. De tal manera fueron seleccionadas aleatoriamente 64 secciones de la base de datos de tal manera que se garantizara la mayor cantidad posible de información espacial-espectral tanto del tejido sano como sintomático, con estas se creó una la imagen de entrenamiento. Adicionalmente, cada sección está acompañada de su imagen ground truth en codificación one-hot, que inicialmente fue generada con el índice vegetal correspondiente a Virus presentado por (Cardona, 2020), y después con su acompañamiento, se realizó una corrección manual de las etiquetas sobre aquellos resultados que así lo requirieron.

Finalmente el procedimiento de entrenamiento fue llevado a cabo haciendo uso de la capacidad computacional proporcionada por la plataforma de Google Colab, contando con un máximo de 25 GB de RAM y una tarjeta gráfica NVIDIA Tesla K80.

En la Figura 5-2a se observa la imagen de entrenamiento constituida por las 64 secciones generadas con anterioridad, en la Figura 5-2b se presenta la imagen de referencia, dónde a cada píxel ha sido asignado una clase, para el caso de tejido sano fue asignada la clase 1 (color azul) y con presencia de virus la clase 2 (color amarillo), de esta manera el modelo de la *HybridSN* cuenta con un área espacial de 400x400 píxeles por 11 canales, resultando en un total de 1.176.000 píxeles de dispuestos para el proceso de entrenamiento.

Figura 5-2: Imagen multiespectral de entrenamiento. a) reconstrucción RGB, b) imagen con cada píxel etiquetado.



En la estructura original de la red fue modificado el tamaño de la capa de entrada y el kernel de la tercera capa convolucionada 3D que fue reducido a un tamaño de 1x1x1. En el proceso de entrenamiento como optimizador fue usado Adam, pero dado que los resultados obtenidos inicialmente no fueron exitosos, este se modificó de acuerdo con el método de optimización estocástica propuesto por (Kingma & Ba, 2015). En la Tabla 5-2 se observan los parámetros iniciales versus los finales del optimizador Adam. Finalmente se implementó un *batch size* de 256 durante 100 épocas, y como función de pérdida, se implementó la entropía cruzada categórica.

Tabla 5-2: Lista de hiperparámetros de optimizador Adam originales versus los implementados.

Hiperparámetro	Valor original	Valor implementado
Taza de aprendizaje	0.001	0.001
Decay	1e-06	0.0
Beta_1	NA	0.9
Beta_2	NA	0.999
Épsilon	NA	1e-08

El proceso de entrenamiento se completó en 6 horas aproximadamente, dando como resultado una eficiencia promedio de 0.9956 (ver Ecuación 5.1) y un error de entrenamiento de 0.018 (ver Ecuación 5.2). La eficiencia dada representa la frecuencia con la que las etiquetas predichas coinciden con las originales. Inicialmente estos resultados presentan una alta capacidad de clasificación por parte del algoritmo, para verificar esta eficiencia se realizó un procedimiento de validación sobre imágenes de hojas de crisantemo con presencia de virus, que no involucraran secciones utilizadas en el proceso de aprendizaje.

$$Eficiencia = \frac{Cantidad\ de\ predicciones\ correctas}{Cantidad\ total\ de\ predicciones\ hechas} \quad (5.1)$$

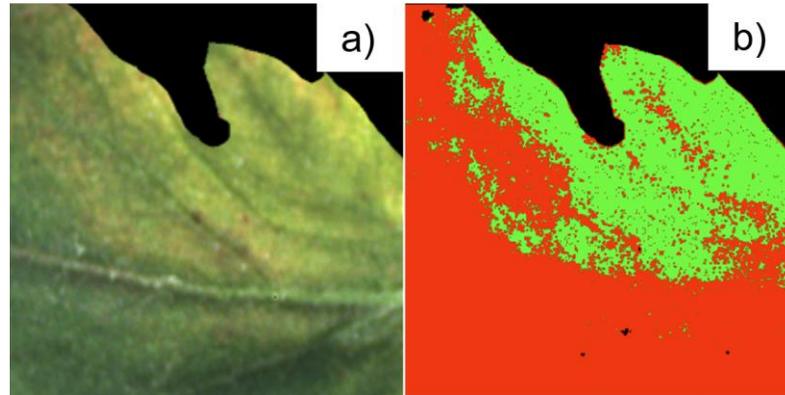
$$Error\ de\ entrenamiento = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5.2)$$

Una imagen multiespectral fue seleccionada aleatoriamente de la base de datos, de esta fue extraída una sección de 400x400 píxeles con sus 11 canales para realizar el proceso de predicción con el modelo entrenado, para evaluar su eficiencia fue utilizado el reporte de clasificación disponible en la librería Sklearn.

En la Figura 5-3a se observa una reconstrucción RGB de la imagen multiespectral utilizada en la validación del modelo entrenado y en la Figura 5-3b se encuentra una representación RGB de las clases predichas para cada píxel. En la imagen de predicciones, las regiones de color rojo representan tejido sano mientras las regiones de color verde implican la presencia de Virus. Inicialmente se observa que el modelo entrenado logra identificar las variaciones presentes en la

sintomatología de Virus al igual que el tejido sano. Finalmente, el tiempo que le toma al algoritmo realizar la predicción es de 8.281s.

Figura 5-3: Sección de hoja con presencia de Virus utilizada en el proceso de validación. a) reconstrucción RGB, b) representación RGB de las predicciones para cada píxel.



Aplicando el reporte de clasificación de Sklearn que se presentan en la Tabla 5-3, se observa de mejor manera la eficiencia del modelo, entre las dos clases, se presenta una mayor capacidad de clasificación correcta en la clase 0 (tejido sano) en comparación con la clase 1 (tejido con síntoma de virus). Al observar la sensibilidad, se presenta que para la clase 1 se identificó una mayor fracción de casos positivos para la clase 1 que en la 0, el score F1 que representa el porcentaje de predicciones positivas que fueron correctas, presenta un resultado más similar en comparación a la precisión, presentando una diferencia del 1% en la eficiencia del modelo al predecir las clases. Considerando que se tiene una diferencia cercana al 24% en la cantidad total de píxeles a evaluar entre las dos clases, se puede concluir que el modelo está realizando que un buen trabajo en el proceso de diferenciación entre tejido sano y con presencia de Virus.

Tabla 5-3: Reporte de clasificación para predicciones en el proceso de validación.

	Precisión	Sensibilidad	F1-score	Soporte
Clase 0	0.97	0.91	0.94	75916
Clase 1	0.89	0.96	0.93	57574
Precisión general			0.93	133490
Macro promedio	0.93	0.94	0.93	133490
Promedio ponderado	0.94	0.93	0.93	133490

5.1.2 Métodos clásicos (ANN y SVM)

Paralelamente, se implementaron dos modelos de clasificación clásicos (ANN y SVM) como comparativa contra el modelo de segmentación semántica. Para esto a cada pixel fue asignada su clase correspondiente (sano o enfermo) y como vector de características fueron empleados los 11 canales que componen la imagen multiespectral. Para generar la base de datos se extrajeron 76.782 muestras de la base de datos, garantizan un balance entre las clases (0 para sana y 1 para enferma).

Las características fueron escaladas de tal manera que su distribución presentara una media 0 y una varianza 1 por medio del algoritmo *StandardScaler* disponible en la librería *sklearn*, con el objetivo que las diferencias en las magnitudes de sus valores no llegaran a afectar el entrenamiento de los algoritmos.

Para el proceso de entrenamiento de la ANN, fue implementado un perceptrón multicapa con 11 neuronas en la capa de entrada y 4 capas ocultas con 15 neuronas por capa oculta, cada una con una función de activación *relu* y en la capa de salida se encuentra una neurona con una función de activación sigmooidal. Para el entrenamiento de este modelo se definió ADAM como optimizador con una tasa de aprendizaje de 0.001, un momento con valor de 0 y la aplicación de momento de Nesterov activada para su actualización durante 100 épocas. En el caso de la SVM, se definió por defecto como kernel una función de base radial (RBF) y un parámetro de regularización C de 1.0. Ambos algoritmos fueron generados empleando la librería *sklearn*.

Para evitar que se presente sesgo en los resultados de clasificación se implementó validación cruzada de K iteraciones (K-fold), donde definieron 10 subconjuntos para el proceso de validación, estos fueron seleccionados por medio de división estratificada, de tal manera que se garantizara el balance de las clases tanto en las secciones de entrenamiento como las de validación, de tal manera que para el entrenamiento se asignó un 80% de la base de datos y un 20% para validación. Para cada una de las divisiones generadas en el proceso de validación cruzada, fue almacenado un reporte de clasificación, posteriormente fue seleccionada la sección que presentó mejores resultados en el proceso para cada una de las divisiones.

En la Tabla 5-4 se presentan los resultados obtenidos en el entrenamiento de la ANN para cada una de las divisiones que se dieron en la validación cruzada, igualmente en la Tabla 5-5 se observan estos mismos resultados para el modelo de SVM. En ambos casos el mejor rendimiento en el proceso de clasificación se dio durante la primera división de la base de datos, de estos modelos, la ANN presenta un mejor desempeño superando todas las métricas de la SVM con diferencias que van del 3-4% aproximadamente, presentando la ANN una eficiencia de clasificación promedio del 98%.

Tabla 5-4: Resultados de entrenamiento con validación cruzada para ANN.

K-fold	Precisión		Sensibilidad		F1-score		Precisión general
	Clase 0	Clase1	Clase 0	Clase1	Clase 0	Clase1	
1	0.9877	0.9805	0.9783	0.9951	0.9830	0.9877	0.9818
2	0.9819	0.9897	0.9771	0.9855	0.9795	0.9876	0.9798
3	0.9860	0.9944	0.9807	0.9820	0.9831	0.9882	0.9824
4	0.9801	0.9780	0.9816	0.9673	0.9808	0.9726	0.9801
5	0.9809	0.9878	0.9826	0.9832	0.9826	0.9855	0.9807
6	0.9744	0.9887	0.9761	0.9796	0.9751	0.9842	0.974
7	0.9782	0.9915	0.9830	0.9871	0.9806	0.9893	0.9813
8	0.9792	0.9819	0.9871	0.9908	0.9831	0.9863	0.9815
9	0.9706	0.9907	0.9873	0.9851	0.9788	0.9879	0.9798
10	0.9747	0.9903	0.9808	0.9828	0.9777	0.9865	0.9781

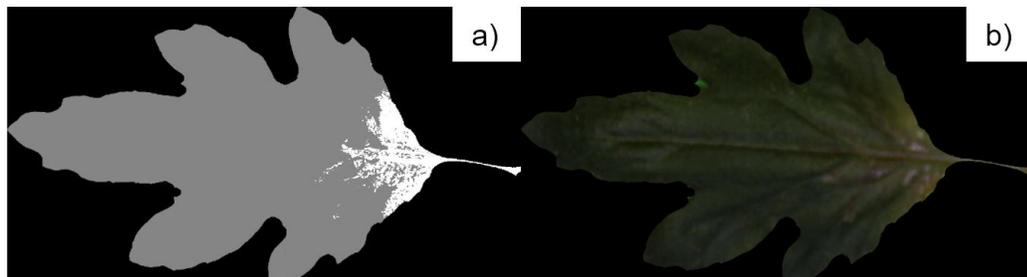
Tabla 5-5: Resultados de entrenamiento con validación cruzada para SVM.

K-fold	Precisión		Sensibilidad		F1-score		Precisión general
	Clase 0	Clase1	Clase 0	Clase1	Clase 0	Clase1	
1	0.9297	0.9549	0.9513	0.9449	0.9404	0.9499	0.9271
2	0.9281	0.9532	0.9462	0.9359	0.9371	0.9445	0.9213
3	0.9223	0.9515	0.944	0.9398	0.9331	0.9456	0.9194
4	0.9268	0.9552	0.9474	0.9304	0.9370	0.9427	0.9201
5	0.9265	0.9526	0.954	0.9396	0.9402	0.9461	0.9244
6	0.9236	0.9565	0.9505	0.9392	0.9369	0.9477	0.9231
7	0.9269	0.9544	0.9439	0.9404	0.9353	0.9473	0.9221
8	0.9262	0.9569	0.9466	0.9384	0.9363	0.9476	0.9229
9	0.9335	0.9536	0.9417	0.9372	0.9376	0.9454	0.9227
10	0.9333	0.9560	0.9439	0.9386	0.9386	0.9472	0.9245

En la Figura 5-4a se presenta el resultado al realizar la predicción de clases del modelo ANN que obtuvo mejor resultado, en esta, el tejido vegetal sano se presenta en un nivel de gris, mientras el

tejido vegetal con presencia de Virus se encuentra en blanco, al comparar el resultado de la predicción se puede notar que las regiones predecidas como enfermas coinciden con aquellas zonas que presentan amarillamiento en la Figura 5-4b, el cuál es causado por la presencia de Virus. El tiempo que le toma al algoritmo realizar la predicción es de 1,667 s.

Figura 5-4: Hoja de crisantemo con presencia de Virus. a) predicción realizada por el modelo de ANN, b) reconstrucción RGB de la hoja.



Al comparar estos resultados con los obtenidos en la implementación del modelo de segmentación semántica, el uso de uno u otro depende en mayor manera de las capacidades de computo con que se cuente, dado que ambos algoritmos presentan resultados satisfactorios en el reconocimiento de la enfermedad.

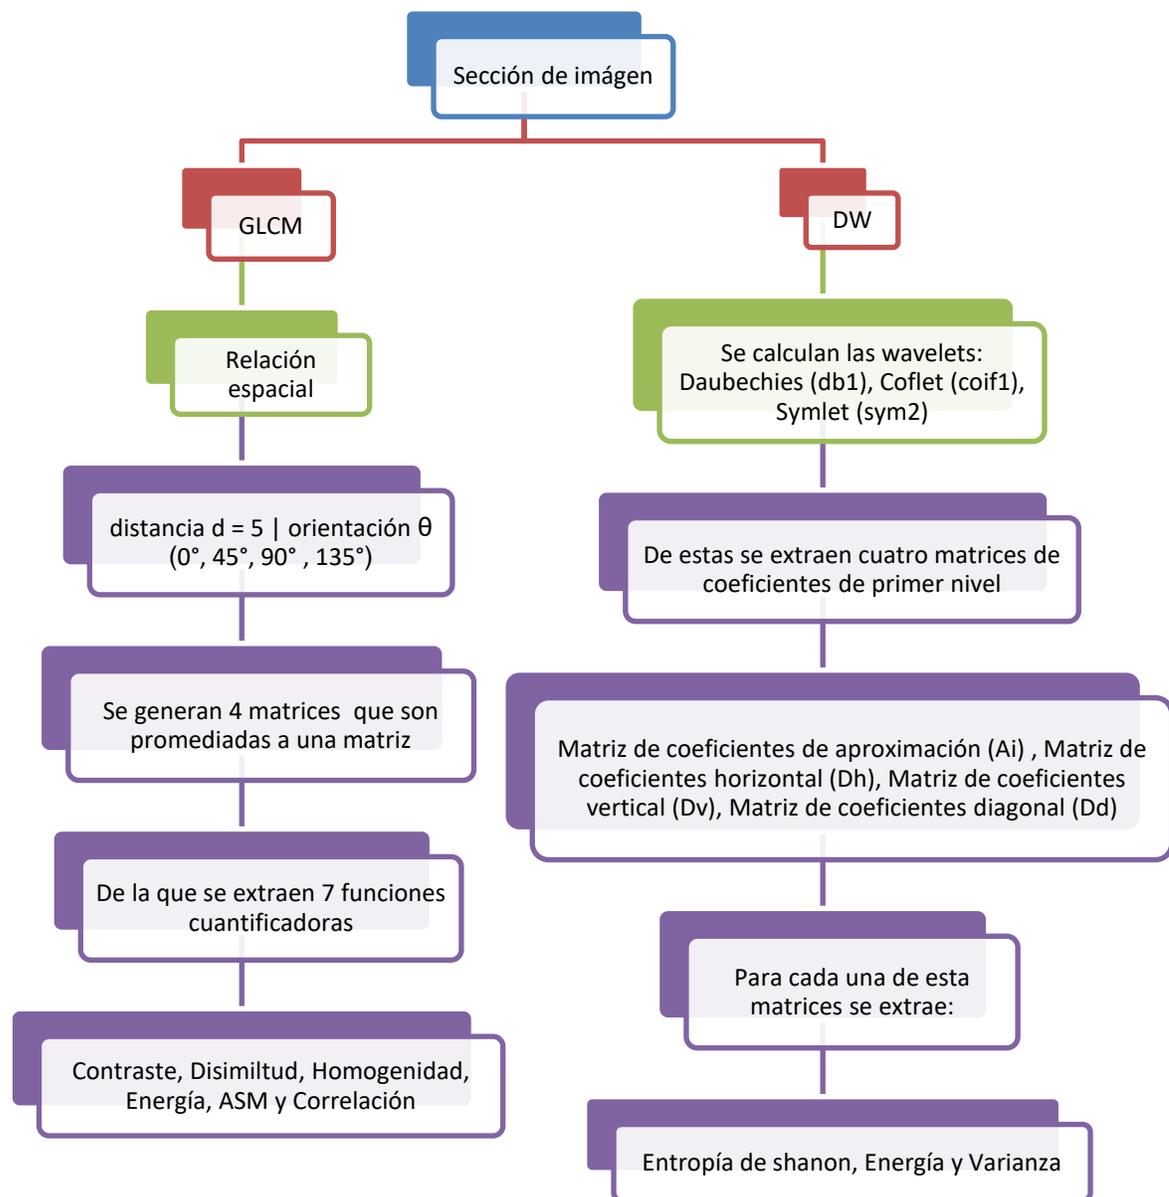
5.1 Clasificación de Trips

En el caso de la sintomatología presentada por la araña de Trips, esta genera decoloraciones o hendiduras en el tejido vegetal, siendo este un patrón característico de esta enfermedad, considerando este suceso para esta problemática se determinó realizar el proceso de caracterización por medio del análisis de textura, basándonos en el trabajo presentado por (Chaddad et al., 2016) donde se realiza un análisis de características multispectrales en la identificación de anomalías en tejidos colorrectales.

Para esto fueron consideradas las matrices de ocurrencia de niveles de grises (GLCMs) y las transformadas wavelet discretas como características de textura a extraer de imagen. En la Figura 5-5 se presenta el procedimiento de extracción de características, este parte de la selección de una región de 30x30 píxeles (ya sea de tejido sano o con presencia de Trips), en total este proceso representa la extracción de 42 características para cada uno de los 11 canales presentes en la

imagen multiespectral, el objetivo es determinar cuál de estos 11 canales presenta una mayor capacidad de clasificación entre el tejido sano e infectado. Como ayuda visual para la selección de la zona afectada, se usa como ayuda la imagen del índice vegetal presentado por (Cardona, 2020) para esta enfermedad. Finalmente el proceso de extracción de características es realizado manualmente seleccionando la zona de interés directamente sobre la imagen multiespectral.

Figura 5-5: Procedimiento de extracción de características tanto de tejido vegetal sano como con presencia de Trips.



Para la identificación de Trips, se realizó la extracción de características de textura siguiendo el procedimiento descrito en el capítulo 2.4.2, de esta manera de las imágenes multiespectrales se extrajeron manualmente 250 secciones de 25x25 píxeles tanto de tejido sano como con sintomatología de Trips, con estas fueron generadas 12 bases de datos cada una con 50 muestras y 2 clases (0 para tejido sano y 1 para tejido con Trips), de las cuales 12 bases de datos 11 corresponden a los canales disponibles en las imágenes multiespectrales generadas con anterioridad y la número 12 corresponde a la imagen resultado de aplicar el índice vegetal propuesto por (Cardona, 2020).

Las características de entrada fueron escaladas de tal manera que su distribución presentara una media 0 y una varianza 1 por medio del algoritmo *StandardScaler* disponible en la librería *sklearn*, con el objetivo que las diferencias en las magnitudes en los valores de las diferentes características no afecten el entrenamiento de los algoritmos.

La ANN consiste en un perceptrón multicapa con 42 neuronas en la capa de entrada, 4 capas ocultas con 165 neuronas por capa oculta, cada una con una función de activación *relu*, en la capa de salida se encuentran dos neuronas con una función de activación sigmoideal. Como parámetros de compilación fueron determinados: como función de pérdida entropía cruzada categórica y como optimizador el descenso estocástico del gradiente con una tasa de aprendizaje de 0.001, un momento con valor de 0 y la aplicación de momento de Nesterov activada para su actualización durante 1000 épocas. Aparte de esto se generación puntos de control de tal manera que aquellos pesos que presentaron un mejor rendimiento al ser evaluarse en tiempo real contra los datos de validación fueran almacenados. En el caso de la SVM, se definió por defecto como kernel una función de base radial (RBF) y un parámetro de regularización C de 1.0. Ambos algoritmos fueron generados empleado la librería *sklearn*.

Para evitar que se presente sesgo en los resultados de clasificación se implementó validación cruzada de K iteraciones (K-fold), dónde definieron 10 subconjuntos para el proceso de validación, estos fueron seleccionados por medio de división estratificada, de tal manera que se garantizara el balance de las clases tanto en las secciones de entrenamiento como las de validación, de tal manera que para el entrenamiento se asignó un 80% de la base de datos y un 20% para validación. Para cada una de las divisiones generadas en el proceso de validación cruzada, fue almacenado un

reporte de clasificación, posteriormente fue seleccionada la sección que presentó mejores resultados en el proceso de validación para cada una de las bases de datos.

En la Tabla 5-6 se observan los resultados obtenidos para la ANN, para cada base de datos evaluada se dan los valores de precisión, *sensibilidad* y *F1-score* por clase, y en la última columna se presenta el valor de precisión general, de estos solo tres canales presentan una precisión general mayor al 90%, de estos el mejor resultado es dado por el canal de 637 nm se da una valor del 93.97% al evaluar el resultado del *F1-score* se presenta una diferencia en la eficiencia de predicción de las clases del 1% dónde para ambas clases se supera el umbral del 93%.

Tabla 5-6: Resultados de entrenamiento para las 12 bases de datos de textura evaluadas con ANN.

Canal (nm)	Precisión		Sensibilidad		F1-score		Precisión general
	Clase 0	Clase1	Clase 0	Clase1	Clase 0	Clase1	
400	0.7736	0.7302	0.7069	0.7931	0.7387	0.7603	0.7500
430	0.8548	0.9074	0.9138	0.8448	0.8833	0.8750	0.8793
460	0.9259	0.8710	0.8621	0.9310	0.8929	0.9000	0.8966
495	0.8889	0.8387	0.8276	0.8966	0.8571	0.8667	0.8624
516	0.9630	0.9032	0.8966	0.9655	0.9286	0.9333	0.9310
551	0.8947	0.8814	0.8793	0.8966	0.8870	0.8889	0.8879
595	0.8772	0.8644	0.8621	0.8793	0.8696	0.8718	0.8707
618	0.9444	0.8871	0.8793	0.9483	0.8107	0.9167	0.9138
637	0.9636	0.9180	0.9138	0.9655	0.9381	0.9412	0.9397
728	0.9216	0.8308	0.8103	0.9310	0.8624	0.8780	0.8707
850	0.8571	0.8333	0.8276	0.8620	0.8421	0.8475	0.8448
PPR	0.8074	0.8548	0.8448	0.9138	0.8750	0.8833	0.8793

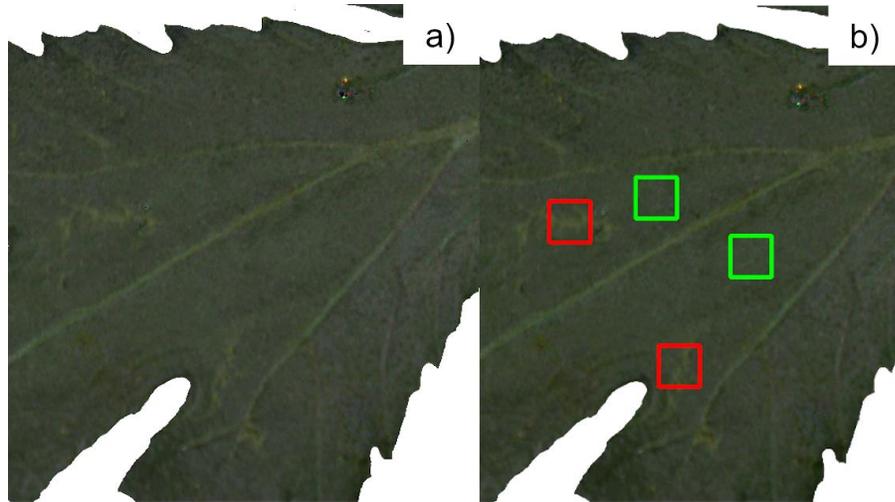
En el caso de la SVM (ver Tabla 5-7) se obtuvo una menor eficiencia en comparación con la ANN, dónde solo tres canales presentan una precisión general mayor al 85%, presentando un mejor resultado el canal de 637 nm (de igual manera sucedió con la ANN) con una eficiencia del 87.93%, al evaluar el resultado del *F1-score* se presenta una diferencia en la eficiencia de predicción de las clases de alrededor del 3% dónde para ambas clases se supera el umbral del 85%.

Tabla 5-7: Resultados de entrenamiento para las 12 bases de datos de textura evaluadas con SVM.

Canal (nm)	Precisión		Sensibilidad		F1-score		Precisión general
	Clase 0	Clase1	Clase 0	Clase1	Clase 0	Clase1	
400	0.8000	0.7273	0.6897	0.8276	0.7407	0.7742	0.7586
430	0.8393	0.8167	0.8103	0.8448	0.8246	0.8305	0.8275
460	0.8519	0.8065	0.7931	0.8621	0.8214	0.8333	0.8275
495	0.8148	0.7742	0.7586	0.8276	0.7857	0.8000	0.7931
516	0.8727	0.8361	0.8276	0.8793	0.8496	0.8571	0.8534
551	0.9565	0.8000	0.7586	0.9655	0.8462	0.8750	0.8620
595	0.9167	0.7941	0.7586	0.9310	0.8302	0.8571	0.8448
618	0.9057	0.8413	0.8276	0.9138	0.8649	0.8760	0.8706
637	0.9074	0.8548	0.8448	0.9138	0.8750	0.8833	0.8793
728	0.8269	0.7656	0.7414	0.8448	0.7818	0.8033	0.7931
850	0.8140	0.6849	0.6034	0.8621	0.6931	0.7634	0.7327
PPR	0.7966	0.8070	0.8103	0.7931	0.8034	0.8000	0.8017

En la Figura 5-6a se encuentra la hoja con las lesiones de trips, por otro lado, en la Figura 5-6b se realiza una prueba en tiempo real de la clasificación del tejido vegetal con el modelo que presentó los mejores resultados (correspondiente a la ANN). Por medio del apuntador se selecciona una región de la hoja presionando el botón izquierdo del ratón sobre estas, a continuación, el algoritmo extrae una región de 25x25 píxeles del canal correspondiente a los 637 nm, extrayendo las características de textura que son asignadas a un vector para realizar la predicción con el modelo entrenado, si la sección del tejido corresponde a una muestra sana (clase 0) se genera un rectángulo de color verde sobre la región seleccionada, en caso tal que el tejido presente sintomatología de Trips el rectángulo será de color rojo. El tiempo que le toma al algoritmo realizar la predicción es de 0.298 s.

Figura 5-6: Hoja de crisantemo con presencia de Trips. a) hoja previa a predicción, b) resultado de predicción sobre el tejido vegetal.



Los resultados obtenidos indican que la longitud de onda de 637 nm presenta un mayor poder discriminatorio al momento de diferencia entre tejido vegetal sano y con sintomatología de Trips, esto se evidencia en ambos modelos evaluados (ANN y SMV), presentando el primero alrededor de un 6% más de eficiencia en la clasificación. Esta situación que difiere con el análisis realizado inicialmente por medio del herramientas de espectroscopía dónde la zona del verde alrededor de los 550 nm se postulaba como la región de interés, este suceso puede presentarse debido a que alrededor de los 650 nm se presenta la zona de absorción de agua en las hojas, esto podría indicar que dado a que el tejido vegetal ha sido dañado por la araña de Trips este es incapaz de realizar la absorción correctamente, y esto se ve reflejado tanto en su comportamiento espectral como espacial, lo que brinda potencial al análisis de textura para este tipo de sintomatologías.

6. Conclusiones y recomendaciones

6.1 Conclusiones

Los sistemas de procesamiento óptico se presentan como una buena herramienta para la solución de problemáticas ingenieriles, dado esto, en este trabajo fueron utilizados dos métodos diferentes para la captura de información por medios ópticos, con el objetivo de evaluar posibles soluciones a las dificultades que se presentan en los procesos de control fitosanitario en la industria floricultora local.

En primer lugar, se empleó la espectroscopía con el fin de explorar el comportamiento espectral de enfermedades manifestadas en hojas de crisantemo, como lo fueron: ácaros, trips y virus. Esto permitió indagar en las problemáticas de la industria floricultora local, al igual que caracterizar algunas de estas con el fin de dar nuevas soluciones al control de plagas en estos cultivos, diferentes de los métodos de revisión convencionales.

Al explorar el comportamiento de las enfermedades evaluadas por medio de la espectroscopía, fue posible determinar algunas regiones espectrales relacionadas con los cambios biológicos que se generan en la hoja. A medida que las enfermedades avanzan significativamente, estas regiones presentan un comportamiento diferenciador entre el tejido sano e infectado, lo que permite a este método como una valiosa herramienta exploratoria de estos comportamientos espectrales, pero no eficiente como un sistema diagnóstico definitivo dada la posibilidad de confundir tejidos vegetales infectados como sanos en etapas tempranas de las enfermedades.

Considerando lo expuesto anteriormente, los resultados obtenidos en la exploración de zonas espectrales relevantes fueron evaluados en un sistema de captura de imágenes multiespectrales, este a diferencia la espectroscopía, permitió contar tanto con información espectral como espacial de la hoja y todos los cambios relacionados con la presencia de las enfermedades evaluadas. Con esto en mente, se realizaron mejoras a un sistema de captura espectral, con la configuración desde cero y puesta a punto de una cámara monocromática, incluyendo el desarrollo de una interfaz de control y captura tanto de la cámara como del sistema de iluminación, de tal manera que se lograra obtener imágenes representativas de las problemáticas evaluadas.

Lo anterior, llevado a cabo en conjunto con el trabajo de maestría del Ingeniero Agrónomo Andrés Cardona, permitió facilitar la etapa de procesamiento de las imágenes multiespectrales adquiridas, en el desarrollo de una metodología para la identificación de enfermedades. Los índices vegetales desarrollados por el ingeniero, aplicados a las imágenes multiespectrales, permitieron a cierto grado, la separación de regiones en la imagen, con síntomas de las enfermedades evaluadas.

Durante este proceso, se encontró que para el caso de ácaros se presenta una significativa dificultad al momento de identificar su presencia en la hoja, dado el leve grado de manifestación de su sintomatología, lo cual implica que realizar una detección temprana de la presencia de esta enfermedad, es netamente necesaria la experticia de un revisor experto en condiciones de campo.

Para el caso virus y trips, se presentó que al implementar algoritmos de clasificación fue posible la diferenciación entre tejidos sanos e infectados, aunque dadas las peculiaridades en la manifestación de cada una de estas enfermedades, fue necesario evaluarlas de maneras separada. Este procedimiento fue verificado por el experto que nos acompañó en este trabajo, algo que permite evaluar directamente la efectividad de la investigación realizada.

De tal manera, se presenta que utilizar en algoritmos de clasificación tanto la información espacial presentada en una imagen, junto con el comportamiento espectral dado por los cambios biológicos que se generan debido a la presencia de enfermedades en las hojas de crisantemo, es una herramienta que puede ayudar en la mejora de los procesos de control de plagas en estos cultivos, al presentarse como una posible alternativa a los prolongados tiempos de entrenamiento que requiere la preparación de un revisor experto.

6.2 Recomendaciones

Este trabajo es un primer acercamiento a la industria floricultora desde el ámbito académico en un entorno controlado de laboratorio y se presentan necesarias futuras investigaciones para llevar este tipo de herramientas a un entorno de operación en campo abierto, de tal manera que sea posible mejorar de forma significativa la eficiencia en los procesos de control fitosanitario en estos cultivos.

Esto requeriría el desarrollo de un sistema más compacto, de tal manera que sea fácil y práctico de implementar en campo abierto, evadiendo las dificultades que se presentan en los invernaderos, dada su estructura y las diferencias en la ubicación geológica de los mismos.

A. Anexo: Especificaciones espectrofotómetro Yokogawa AQ6373

11.1 Specifications

Item	Specifications
Applicable fiber	SM, GI (50/125 μm , 62.5/125 μm), Large core size fibers (core diameter of up to 800 μm)
Measurement wavelength range ¹	350 to 1200 nm
Span ¹	0.5 nm to 850 nm (entire wavelength range), 0 nm
Wavelength accuracy ^{1,2}	± 0.2 nm (400 to 1100 nm) ± 0.05 nm (633 nm)
Wavelength resolution setting ^{1,3}	0.02, 0.05, 0.1, 0.2, 0.5, 1.0, 2.0, 5.0, 10.0 nm, and 0.01 nm (at a measured wavelength range of 400 to 470 nm)
Measurement data point (Wavelength sampling points)	101 to 50001, AUTO
Wavelength sampling resolution	0.001 nm minimum
Level sensitivity setting	NORM_HOLD, NORM_AUTO, NORMAL, MID, HIGH1, HIGH2 and HIGH3
High dynamic range mode	SWITCH (Sensitivity: MID, HIGH1, HIGH2, HIGH3)
Level sensitivity ^{4,5}	-80 dBm (500 to 1000 nm, resolution: 0.2 nm or more, measuring sensitivity: HIGH3) -60 dBm (400 to 500 nm, resolution: 0.2 nm or more, measurement sensitivity: HIGH3) -60 dBm (1000 to 1100 nm, resolution: 0.2 nm or more, measurement sensitivity: HIGH3)
Level accuracy ⁴	± 1.0 dB (850 nm, -20 dBm, resolution: 0.2 nm or more, sensitivity setting: MID, HIGH1, HIGH2, HIGH3) (when using an (MFD 5 μm @850 nm, NA 0.14 (typ.) SMF)
Level linearity ⁴	± 0.2 dB (input level: -40 to +0 dBm, measuring sensitivity: HIGH1, HIGH2, HIGH3)
Safe max. input power ⁴	+20 dBm (total light input power at 550 to 1100 nm) +10 dBm (total light input power at 400 to 550 nm)
Dynamic range ¹	60 dB or more (633 nm, ± 0.5 nm of peak wavelength, resolution: 0.02 nm)
Sweep time ^{1,6}	0.5 s (NORM_AUTO), 1 s (NORMAL) 2 s (MID) 5 s (HIGH1), 20 s (HIGH2), 75 s (HIGH3)
Function	
Automatic measurement	Program function (64 programs, 200 steps)
Setting of measuring conditions	Center wavelength, span, wavelength sampling points, wavelength resolution, measurement sensitivity, high dynamic mode, averaging times (1 to 999), sweep (single, repeat, AUTO: automatically sets measuring conditions), sweep between marker function, pulse light measurement function, smoothing function, external trigger measurement function, sweep status output function, analog output function, air/vacuum wavelength measurement function, template-based Pass/Fail judgment function

Display	Level scale (0.1 to 10 dB/div., linear scale), level subscale (0.1 to 10 dB/div., linear scale), reference level display, vertical axis DIV display (8, 10, 12), horizontal axis wavelength/frequency display, horizontal axis scale zoom in/out display, measuring conditions display, noise mask display, data table display, label display, split screen display, percent display, power density (dB/nm) display, dB/km display, template display
Traces	Simultaneous display of 7 independent traces, write mode fixed mode setting, show/hide setting, max/min value detection display, calculation between traces display, roll averaging display (sweep average) (2 to 100 times), normalized display, curve fit display (peak curve fit, marker curve fit), trace copy function, trace clear function, saving/loading all trace function
Marker/Search	Delta markers (1024 points maximum), vertical/horizontal line markers, peak search, bottom search, auto search (ON/OFF), search between vertical axis line markers, search within zoom area
Analysis	Spectral width analysis (threshold, envelope, RMS, Peak RMS, notch), OSNR (WDM) analysis, chromaticity coordinate analysis (COLOR analysis), filter peak/bottom analysis, DFB-LD analysis, FP-LD analysis, LED analysis, SMSR analysis, power analysis, PMD analysis, Pass/Fail judgment from template, auto analysis, analysis between vertical axis line markers, analysis within the zoom area
Other	Auto alignment function with built-in reference light source

Item	Specifications
Data storage	
Internal memory	64 traces, 64 programs, 3 templates
Internal storage	128 MB max
External storage	USB storage media (USB memory/HDD), format: FAT32
File types	CSV (text), binary, bitmap, TIFF
Interfaces	
Remote control	GP-IB, RS-232, Ethernet (TCP/IP) AQ6317 series compliant commands (IEEE488.1) and IEEE488.2
Categories	GP-IB x 2 (for standard and external control), RS-232, Ethernet, USB1.1 x 2, PS/2 (for keyboard), SVGA output, analog output port, trigger input port, trigger output port
Optical connectors	Fixed to FC type
Printer	Built-in thermal printer (factory option)
Display ⁸	10.4" color LCD (resolution: 800 x 600 pixels)
Power requirement	100 to 240 VAC, 50/60 Hz, approximately 150 VA
Environment conditions	Operating temperature range: +5 to +35°C Operating humidity range: -10 to +50°C Ambient humidity: 80% RH or less (no condensation)
Recommended calibration period	1 year
External dimensions ⁷	Approximately 426 (W) x 221 (H) x 459 (D) mm
Mass	Approximately 20 kg (excluding built-in printer)
Safety standards	Conforming standards EN61010-1 EN60825-1 Pollution degree 2 ⁹

Emissions	Conforming standards	EN61326-1 EN55011 Class A, Group 1 EN61000-3-2 EN61000-3-3 EMC Regulatory Arrangement in Australia and New Zealand EN 55011 Class A, Group 1 Korea Electromagnetic Conformity Standard (한국 전자파적합성기준) This is a class A instrument (industrial use). Wireless interference may occur in home environments. If so, the user must take appropriate countermeasures.	Class A
	Cable conditions	<ul style="list-style-type: none"> • TRIGGER IN, TRIGGER OUT, ANALOG OUT terminal. Use a BNC cable¹⁰ • Use a serial (RS-232) interface connector and RS-232 shielded cable.¹⁰ • Use an Ethernet connector and a category 5 or higher Ethernet cable.¹¹ • Use a VIDEO OUT connector and a D-sub 15pin VGA shielded cable¹⁰ • Use a USB peripheral (such as a mouse) that uses a USB port and shielded cable¹⁰ • Use a keyboard connector and PS/2 shielded cable¹⁰ • Use the GP-IB1 or GP-IB2 interface connector and a GP-IB shielded cable¹⁰ 	

Item

			Specifications
Immunity locations)	Conforming standards	EN61326-1	Table 2 (For use in industrial
	Effect in immunity environment		Wavelength measurement sensitivity: Within ± 0.1
nm	Cable conditions		Same as above emission cable conditions.

1: Horizontal axis scale: In wavelength display mode

2: After user wavelength calibration with a 633 nm HeNe laser

3: The actual power value of the wavelength resolution differs depending on the measured wavelength. The widest is approximately 8 nm, when set to 10 nm.

4: Vertical scale: absolute value level display mode

5: Typical value. AVR: 10 times

6: High dynamic range mode: OFF, pulse light measurement mode: OFF, no. of sampling points: 1001, averaging count: 1, and span of 100 nm or less (excludes the wavelength at which the order of diffraction switches, and the wavelength at which the optical filter switches).

7: Note that this excludes the protector and handle

8: The LDC display may contain defective pixels (always ON or always OFF).

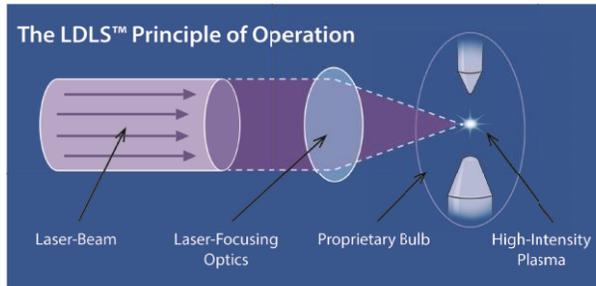
(0.002% or fewer of all pixels including RGB). Does not indicate a general malfunction.

9: Pollution degree refers to the degree of adherence by a solid, liquid, or vapor that reduces the withstand voltage or surface resistance factor. Pollution degree 1 applies to closed atmospheres (no pollution, or only dry, non-conductive pollution). Pollution degree 2 applies to normal indoor atmospheres (with only non-conductive pollution).

10: Use a cable of 3 m in length or less.

11: Use a cable of 30 m in length or less.

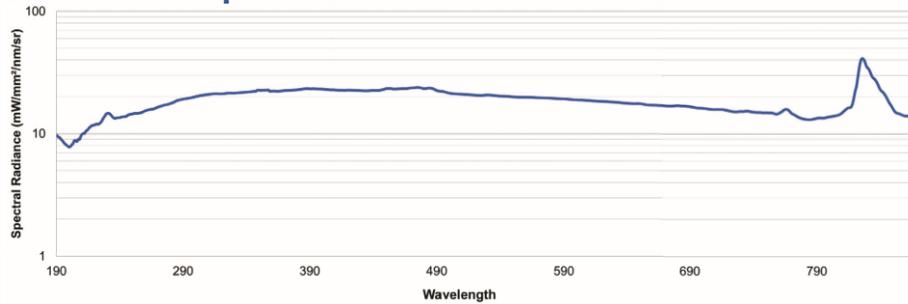
B. Anexo: Especificaciones fuente de luz blanca EQ-99X



EQ-99X lamp house with power supply



EQ-99X LDLS Spectral Radiance



Specifications

Overview

- Spectral output from 170nm to 2100nm
- Large collectable view angle – Numerical Aperture (NA): up to 0.47
- Typical bulb life > 9,000 hrs.
- Flexible optical interface for free-space optics (SM1 thread)
- Various precision reflective coupling optics are available from Energetiq - call for details

Physical Specifications

	System Dimensions (H x W x D)	Weight
• Lamp House	82.3 x 85.7 x 76.2 mm (3.2 x 3.4 x 3.0 in)	0.7 kg (1.5 lbs)
• Power Supply	107 x 111 x 254 mm (4.2 x 4.4 x 10 in) (excl feet)	1.4kg (3 lbs)

Utility Requirements

- Electrical
 - Cooling
 - Nitrogen
 - Compliance
- 100-240v, 50/60Hz, 2.5A
Ambient air, no auxiliary cooling necessary
Recommended purging for longest life & for DUV operation, Grade 6
CE Mark, Class 1 Laser Product



C. Anexo: Datos espectrales capturados por el espectro fotómetro

```

73CSV
// AQ6373 OPTICAL SPECTRUM ANALYZER //
35
CTRWL 725
SPAN 750
START WL 350
STOP WL 1100
WLFREQ 0
REFL -58
LSCL -10
BASEL 0
RESLN 5
AVG 4
SMPLAUTO 1
SMPL 751
SMPLINTVL 1
HIGH2
MEAS
LSUNT 0
NMSKH OFF
RESCOR 0
SMOOTH 0
CHGPT 132
RESCAL0_0 9933
RESCAL0_1 -5601
RESCAL0_2 3545057
RESCAL1_0 10245
RESCAL1_1 32519
RESCAL1_2 -20585070
CORESIZE 1

```

[TRACE DATA]

350 3.006E-10
351 1.092E-08
352 2.252E-09
353 4.692E-09
354 2.449E-08
355 9.299E-09
356 1.126E-08
357 1.095E-08
358 -4.502E-09
359 2.983E-08

.

.

.

.

.

1093 1.297E-07
1094 1.29E-07
1095 1.228E-07
1096 1.255E-07
1097 1.236E-07
1098 1.183E-07
1099 1.177E-07
1100 1.175E-07

D. Anexo: Especificaciones cámara Basler acA2040-55um

Specification	acA2040-55um	acA2040-55uc
Resolution (H x V pixels)	2064 x 1544 (full resolution) 2048 x 1536 (default resolution; see Section 1.2 on page 2)	
Sensor Type	Sony IMX265LLR-C Progressive scan CMOS Global shutter	Sony IMX265LQR-C Progressive scan CMOS Global shutter
Optical Size	1/1.8"	
Effective Sensor Diagonal	8.9 mm	
Pixel Size (H x V)	3.45 μm x 3.45 μm	
Max. Frame Rate	55 fps (at default and full resolution; see Section 1.2 on page 2)	
Mono/Color	Mono or color (color cameras include a Bayer pattern RGB filter on the sensor)	
Data Output Type	USB 3.0, nominal max. 5 Gbit/s (SuperSpeed)	
Pixel Formats	Mono 8 Mono 12p Mono 12	Mono 8 RGB 8 Bayer RG 8 BGR 8 Bayer RG 12 YCbCr422_8 Bayer RG 12p
Synchronization	Via hardware trigger, via software trigger or free run	
Exposure Time Control	Via hardware trigger or programmable via the camera API	
Camera Power Requirements	Nominal +5 VDC; SELV and LPS compliant and in accord with the Universal Serial Bus 3.0 specification; supplied via the camera's USB 3.0 port.	
	Mono Models: ≈ 2.5 W (typical) @ 5 VDC	
	Color Models: ≈ 2.6 W (typical) @ 5 VDC	
I/O Lines	1 opto-isolated input line, 1 opto-isolated output line, and 2 direct-coupled GPIO lines; power supplies must meet the SELV and LPS requirements	
Lens Mount	C-mount	

Size (L x W x H)	29.3 mm x 29 mm x 29 mm (without cylindric housing extension or connectors) 48.2 mm x 29 mm x 29 mm (with cylindric housing extension and connectors)
Weight	<80 g
Conformity	CE (includes RoHS), UL in preparation, FCC, GenICam V. 2.x (includes PFNC V. 2.x and SFNC V. 2.x), IP30, USB3 Vision, USB-IF in preparation, REACH The EU Declaration of Conformity is available on the Basler website: www.baslerweb.com
Software	Basler pylon Camera Software Suite (version 4.0 or higher) Available for Windows (x86, x64) and Linux (x86 32 bit, x86 64-bit, ARM).

Bibliografía

- Abbasi, S., Mokhtarian, F., & Kittler, J. (1997). Reliable Classification of Chromatic Leaf Curvature Scale Space. *International Conference on Scale-Space Theories in Computer Vision*, 284–295.
- Ag, B. (2015). *Basler ace aca2040-55u*. <https://www.baslerweb.com/en/products/cameras/area-scan-cameras/ace/aca2040-55um/>
- Agropimos. (2018). *TIPOS DE INVERNADEROS EN COLOMBIA*. <https://www.agropinos.com/tipos-de-invernaderos>
- Aikens, R. S., Agard, D. A., & Sedat, J. W. (2008). *Solid-State Imagers for Microscopy* (pp. 291–313). [https://doi.org/10.1016/s0091-679x\(08\)60199-5](https://doi.org/10.1016/s0091-679x(08)60199-5)
- Ali, H., Lali, M. I., Nawaz, M. Z., Sharif, M., & Saleem, B. A. (2017). Symptom based automated detection of citrus diseases using color histogram and textural descriptors. *Computers and Electronics in Agriculture*, 138, 92–104. <https://doi.org/10.1016/j.compag.2017.04.008>
- Anand, R., Veni, S., & Aravindh, J. (2016). An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method. *2016 International Conference on Recent Trends in Information Technology, ICRTIT 2016*. <https://doi.org/10.1109/ICRTIT.2016.7569531>
- Ashourloo, D., Mobasheri, M. R., & Huete, A. (2014). Developing two spectral disease indices for detection of wheat leaf rust (*Puccinia triticina*). *Remote Sensing*, 6(6), 4723–4740. <https://doi.org/10.3390/rs6064723>
- Asocolflores. (2015). Editorial: Desarrollo social. *Floricultura Colombiana No. 5.*, 28. <https://doi.org/Revista de la Asociación Colombiana de Exportadores de Flores>
- Cut Flowers and Greenery Import Manual Cut Flowers and Greenery, 148 (2014).
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. *Biosystems Engineering*, 144, 52–60. <https://doi.org/10.1016/j.biosystemseng.2016.01.017>
- Barbedo, J. G. A. (2017). A new automatic method for disease symptom segmentation in digital photographs of plant leaves. *European Journal of Plant Pathology*, 147(2), 349–364. <https://doi.org/10.1007/s10658-016-1007-6>
- Barbedo, J. G. A., Koenigkan, L. V., & Santos, T. T. (2016). Identifying multiple plant diseases using digital image processing. *Biosystems Engineering*, 147, 104–116.

- <https://doi.org/10.1016/j.biosystemseng.2016.03.012>
- Behmann, J., Steinrücken, J., & Plümer, L. (2014). Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 98–111. <https://doi.org/10.1016/j.isprsjprs.2014.03.016>
- Bettioli, W.; Rivera, M.; Mondino, P.; Montealegre, J.; Colmenárez, Y. (2014). Control biológico de enfermedades de plantas en Argentina. En *Control biológico de enfermedades de plantas en América Latina y el Caribe*. <https://doi.org/10.13140/2.1.2368.5922>
- Cardona, A. M. (s/f). *EVALUACIÓN DE TÉCNICAS DE ANÁLISIS MULTIESPECTRALES PARA EL RECONOCIMIENTO DE PROBLEMAS SANITARIOS EN CRISANTEMO*. Universidad Católica de Oriente.
- Castaño Duque, D., & Restrepo, J. F. (2014). *Aseguramiento de la calidad en el área de producción en un cultivo de flores* [Corporación Universitaria Lasallista]. http://repository.lasallista.edu.co/dspace/bitstream/10567/1111/1/Aseguramiento_calidad_area_produccion_cultivo_flores.pdf
- Chaddad, A., Desrosiers, C., Hassan, L., & Toews, M. (2016). Multispectral texture analysis of histopathological abnormalities in colorectal tissues. En *Proceedings - International Conference on Image Processing, ICIP (Vols. 2016-Augus)*. <https://doi.org/10.1109/ICIP.2016.7532835>
- Dyring, E. (1973). Principles of Remote Sensing. En *Ambio* (Vol. 11, Número 3). <https://doi.org/10.2307/633049>
- El Colombiano. (2020). *Flores paisas para San Valentín valdrán \$202.801 millones*. <https://www.elcolombiano.com/negocios/agro/san-valentin-con-flores-de-antioquia-CD12442527>
- Estudios, D. De, & Centro, D. L. (2017). *Universidad Autónoma de Nuevo León*.
- Fang, Y., & Ramasamy, R. P. (2015). Current and prospective methods for plant disease detection. *Biosensors*, 5(3). <https://doi.org/10.3390/bios5030537>
- Gómez Granda, J. D., Luz Estrella, M. Z., & Urrego David, D. Y. (2018). *Lámpara Hiperespectral*.
- Goodridge, W., Bernard, M., Jordan, R., & Rampersad, R. (2017). Intelligent diagnosis of diseases in plants using a hybrid Multi-Criteria decision making technique. *Computers and Electronics in Agriculture*, 133, 80–87. <https://doi.org/10.1016/j.compag.2016.12.003>

- Instituto Colombiano Agropecuario. (1997). *Resolución 578 del 26 de marzo de 1997.pdf* (p. 1). Instituto Colombiano Agropecuario.
- Instituto Colombiano Agropecuario. (2008). *Guía para toma envío muestras*.
- Izzuddin, M. A., Idris, A. S., Nisfariza, M. N., Nordiana, A. A., Shafri, H. Z. M., & Ezzati, B. (2017). The development of spectral indices for early detection of *Ganoderma* disease in oil palm seedlings. *International Journal of Remote Sensing*, 1–23. <https://doi.org/10.1080/01431161.2017.1335908>
- Jin, X., Liu, S., Baret, F., Hemerlé, M., & Comar, A. (2017). Estimates of plant density of wheat crops at emergence from very low altitude UAV imagery. *Remote Sensing of Environment*, 198, 105–114. <https://doi.org/10.1016/j.rse.2017.06.007>
- Karuppiah, K., Senthilkumar, T., Jayas, D. S., & White, N. D. G. (2016). Detection of fungal infection in five different pulses using near-infrared hyperspectral imaging. *Journal of Stored Products Research*, 65, 13–18. <https://doi.org/10.1016/j.jspr.2015.11.005>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <http://arxiv.org/abs/1412.6980>
- Klima, R. (2012). Theory of reflectance and emittance spectroscopy. *Meteoritics & Planetary Science*, 47(8), 1403–1404. <https://doi.org/10.1111/j.1945-5100.2012.01391.x>
- Krishna, R. (2017). Computer Vision :Foundation and Applications. *Reference Book*, 213.
- Labsphere. (2010). *Technical guide: reference materials and coatings*. <http://www.labsphere.com/uploads/technical-guides/a-guide-to-reflectance-materials-and-coatings.pdf>
- Leucker, M., Mahlein, A.-K., Steiner, U., & Oerke, E.-C. (2015). Improvement of Lesion Phenotyping in *Cercospora beticola*–Sugar Beet Interaction by Hyperspectral Imaging. *Phytopathology*, 106(2), 177–184. <https://doi.org/10.1094/PHYTO-04-15-0100-R>
- Lunadei, L., Diezma, B., Lleó, L., Ruiz-Garcia, L., Cantalapiedra, S., & Ruiz-Altisent, M. (2012). Monitoring of fresh-cut spinach leaves through a multispectral vision system. *Postharvest Biology and Technology*, 63(1), 74–84. <https://doi.org/10.1016/j.postharvbio.2011.08.004>
- Ma, J., Du, K., Zhang, L., Zheng, F., Chu, J., & Sun, Z. (2017). A segmentation method for greenhouse vegetable foliar disease spots images using color information and region growing. *Computers and Electronics in Agriculture*, 142, 110–117.

<https://doi.org/10.1016/j.compag.2017.08.023>

Marques, E. J. N., De Freitas, S. T., Pimentel, M. F., & Pasquini, C. (2016). Rapid and non-destructive determination of quality parameters in the “Tommy Atkins” mango using a novel handheld near infrared spectrometer. *Food Chemistry*, *197*, 1207–1214.

<https://doi.org/10.1016/j.foodchem.2015.11.080>

Matlab. (2019). *Image Types*. https://www.mathworks.com/help/matlab/creating_plots/image-types.html

Media Production Lab. (2019). *2D IMAGE DIGITAL REPRESENTATION*.

<https://edtech.engineering.utoronto.ca/object/2d-image-digital-representation>

Meng, Q., Qiu, R., He, J., Zhang, M., Ma, X., & Liu, G. (2015). Development of agricultural implement system based on machine vision and fuzzy control. *Computers and Electronics in Agriculture*, *112*, 128–138. <https://doi.org/10.1016/j.compag.2014.11.006>

Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, *24*(14), 2855–2877.

<https://doi.org/10.1080/01431160210163074>

Pacioni, G. (1982). *Guía de hongos*. Grijalbo.

Perez-Sanz, F., Navarro, P. J., & Egea-Cortines, M. (2017). Plant phenomics: An overview of image acquisition technologies and image data analysis algorithms. En *GigaScience* (Vol. 6, Número 11). Oxford University Press. <https://doi.org/10.1093/gigascience/gix092>

Qiao, X., Jiang, J., Qi, X., Guo, H., & Yuan, D. (2017). Utilization of spectral-spatial characteristics in shortwave infrared hyperspectral images to classify and identify fungi-contaminated peanuts. *Food Chemistry*, *220*, 393–399. <https://doi.org/10.1016/j.foodchem.2016.09.119>

Rodriguez-Moreno, F., Kren, J., Zemek, F., Novak, J., Lukas, V., & Píkl, M. (2017). Advantage of multispectral imaging with sub-centimeter resolution in precision agriculture: generalization of training for supervised classification. *Precision Agriculture*, *18*(4), 615–634.

<https://doi.org/10.1007/s11119-016-9478-1>

Rojas Vega, J. P. (2011). Roya blanca del Crisantemo. *Puccinia horiana*. *Plagas y enfermedades de carácter cuarentenario en flores de corte*, 1–20.

<http://www.ica.gov.co/getattachment/1e58698b-b79b-4829-9255-415955c924b3/Publicacion-5.aspx>

- Roy, S. K., Krishna, G., Dubey, S. R., & Chaudhuri, B. B. (2020). HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*, 17(2), 277–281. <https://doi.org/10.1109/LGRS.2019.2918719>
- Shimadzu. (2019). *Solid Sample Reflectance Measurements*.
https://www.shimadzu.com/an/uv/support/fundamentals/reflectance_measurements.html
- Sowmya, V., Soman, K. P., & Hassaballah, M. (2019). Hyperspectral image: Fundamentals and advances. En *Studies in Computational Intelligence* (Vol. 804, pp. 401–424). Springer Verlag. https://doi.org/10.1007/978-3-030-03000-1_16
- Szeliski, R. (2010). Computer Vision : Algorithms and Applications. *Computer*, 5, 832.
<https://doi.org/10.1007/978-1-84882-935-0>
- Thomas, S., Kuska, M. T., Bohnenkamp, D., Brugger, A., Alisaac, E., Wahabzada, M., Behmann, J., & Mahlein, A. K. (2018). Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. En *Journal of Plant Diseases and Protection* (Vol. 125, Número 1, pp. 5–20). Springer Berlin Heidelberg. <https://doi.org/10.1007/s41348-017-0124-6>
- Tyagi, V. (2018). Understanding Digital Image Processing. En *Understanding Digital Image Processing*. CRC Press. <https://doi.org/10.1201/9781315123905>
- Veys, C., Chatziavgerinos, F., ALSuwaidi, A., Hibbert, J., Hansen, M., Bernotas, G., Smith, M., Yin, H., Rolfe, S., & Grieve, B. (2019). Multispectral imaging for presymptomatic analysis of light leaf spot in oilseed rape. *Plant Methods*, 15(1). <https://doi.org/10.1186/s13007-019-0389-9>
- Wageningen. (2016). *Measurement of thrips damage using hyperspectral image processing*.
<https://www.wur.nl/nl/nieuws/Measurement-of-thrips-damage-using-hyperspectral-image-processing-.htm>
- Wahabzada, M., Mahlein, A.-K., Bauckhage, C., Steiner, U., Oerke, E.-C., & Kersting, K. (2016). Plant Phenotyping using Probabilistic Topic Models: Uncovering the Hyperspectral Language of Plants. *Scientific reports*, 6, 22482. <https://doi.org/10.1038/srep22482>
- Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, 1–17. <https://doi.org/10.1155/2017/1353691>
- Zhang, J., Wang, N., Yuan, L., Chen, F., & Wu, K. (2017). Discrimination of winter wheat disease and insect stresses using continuous wavelet features extracted from foliar spectral measurements. *Biosystems Engineering*, 162, 20–29.

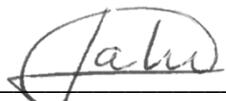
<https://doi.org/10.1016/j.biosystemseng.2017.07.003>

Zhang, S., Wang, H., Huang, W., & You, Z. (2018). Plant diseased leaf segmentation and recognition by fusion of superpixel, K-means and PHOG. *Optik*, 157, 866–872.

<https://doi.org/10.1016/j.ijleo.2017.11.190>

Zhu, H., Chu, B., Zhang, C., Liu, F., Jiang, L., & He, Y. (2017). Hyperspectral Imaging for Presymptomatic Detection of Tobacco Disease with Successive Projections Algorithm and Machine-learning Classifiers. *Scientific Reports*, 7(1). <https://doi.org/10.1038/s41598-017-04501-2>

Carlos Andrés Sánchez Pías
Firma del Estudiante


Firma del Asesor