

**DISEÑO E IMPLEMENTACIÓN DE UN ALGORITMO BASADO EN
APRENDIZAJE PROFUNDO PARA LA EXTRACCIÓN DE PROPIEDADES Y
ATRIBUTOS DISCRIMINANTES DE FRUTOS CÍTRICOS DESDE IMÁGENES
ESPECTRALES TIPO VNIR.**

JHONNY ALFONSO PATIÑO PEÑALOZA



**PROGRAMA DE FÍSICA
DEPARTAMENTO DE FÍSICA
FACULTAD DE CIENCIAS BÁSICAS
UNIVERSIDAD DE PAMPLONA
PAMPLONA 2024**

**DISEÑO E IMPLEMENTACIÓN DE UN ALGORITMO BASADO EN
APRENDIZAJE PROFUNDO PARA LA EXTRACCIÓN DE PROPIEDADES Y
ATRIBUTOS DISCRIMINANTES DE FRUTOS CÍTRICOS DESDE IMÁGENES
ESPECTRALES TIPO VNIR.**

Trabajo de grado presentado como requisito para optar al título de FÍSICO

JHONNY ALFONSO PATIÑO PEÑALOZA

Director: NESTOR ALONSO ARIAS HERNANDEZ

Doctor en Ciencias Naturales – Física



Grupo de Investigaciones Óptica Moderna

PROGRAMA DE FÍSICA

DEPARTAMENTO DE FÍSICA

FACULTAD DE CIENCIAS BÁSICAS

UNIVERSIDAD DE PAMPLONA

PAMPLONA 2024

DEDICATORIA

Esta dedicatoria va principalmente a mi madre, quien ha sido mi pilar para continuar adelante y un ejemplo de perseverancia, quien ha confiado en mi capacidad y en mi esfuerzo. Todo el apoyo que me has brindado ha sido fundamental para realizar este trabajo de grado. ¡GRACIAS!

AGRADECIMIENTOS

Agradezco profundamente a mi tutor y profesor, el doctor Néstor Alonso Arias Hernández, por su guía precisa y su inmensa paciencia durante la realización de este trabajo de grado. Extiendo también mi gratitud a todos mis compañeros que me acompañaron a lo largo del camino y, en especial, a personas sin quienes este logro no habría sido posible: mis amigos Yeinner, Luis y Osmar, con quienes compartí cada etapa de este proceso desde sus inicios.

Agradecemos al Ministerio de Ciencias, Tecnología e Innovación (MinCiencias) por el financiamiento del proyecto "*Diseño e implementación de un sistema óptico-computacional tipo pushbroom para la clasificación de frutos cítricos de la agroindustria santandereana*" (código 82271), seleccionado en la Convocatoria 890 para el fortalecimiento de la Ciencia, la Tecnología y la Innovación (CTeI) en Instituciones de Educación Superior (IES) de 2020, que sirvió como soporte para el desarrollo del presente trabajo.

TABLA DE FIGURAS

Figura 4.1 Una red neuronal artificial multicapa[Autor].....	8
Figura 4.2 Interacción de la Luz con la Materia: Ejemplo de Reflectancia en un Tomate[Autor].	10
Figura 4.3 Comparación de tipo de imágenes de acuerdo a la cantidad de longitudes de onda registradas[Autor].....	11
Figura 4.4 Espectro Electromagnético[26].	12
Figura 4.5 Clasificación del Espectro Visible e Infrarrojo: Divisiones en Infrarrojo Cercano (NIR), Medio (Mid IR) y Lejano (Far IR) con sus rangos de longitud de onda[27].	13
Figura 4.6 Diagrama esquemático de un hipercubo de imagen hiperespectral para una pieza de carne que muestra la relación entre la información espectral y espacial en tres dimensiones[29].	14
Figura 4.7 Representaciones conceptuales de los modos de adquisición de imágenes. (a) Modo de escaneo por longitud de onda; (b) Modo de escaneo[36].	19
Figura 4.8 Diferentes imágenes del mismo fruto afectado por moho verde en luz visible, infrarrojo cercano, fluorescencia e iluminación ultravioleta[37].	21
Figura 4.9 a) Dispersión de la luz mediante un prisma; b) Difracción de la luz con una red de difracción; c) Sistema híbrido PGP (Prisma-Red de Difracción-Prisma) mostrando la separación de longitudes de onda.[Autor]	25
Figura 4.10 Sensores CCD y CMOS[Autor].	27
Figura 4.11 Principio de funcionamiento del espectrógrafo de prisma-rejilla-prisma (PGP) (cortesía de Specim Ltd)[41]	27
Figura 4.12 Esquema de sistema pushbroom incorporado en una banda transportadora[Autor].	30
Figura 4.13 Arquitecturas tradicionales de adquisición de imágenes espectrales. (a) Sensor Whiskbroom, (b) Sensor Pushbroom, y (c) Filtrado espectral[Autor].	31
Figura 4.14 Calibración espectral para un sistema de imágenes hiperespectrales de escaneo lineal utilizando lámparas de calibración de xenón y mercurio-argón[36].	33
Figura 4.15 Calibración espacial para un sistema de imágenes hiperespectrales de escaneo lineal utilizando un papel blanco impreso con líneas paralelas delgadas separadas por 2 mm[36].	34
Figura 4.16 Estructura simple de una neuronal artificial[Autor].....	37
Figura 4.17 Esquema red neuronal [Autor].	37
Figura 4.18 PCA aplicándose a los datos hiperespectrales para generar imágenes de puntuaciones[Autor].	42
Figura 5.1 Conceptualización general del sistema[Autor].	45
Figura 5.2 Cámara Specim FX10e	46
Figura 5.3 Esquema de sistema pushbroom incorporado en una banda transportadora[Autor]...	47
Figura 5.4 a) Firma espectral del blanco; b) Firma espectral del negro[Autor].	49
Figura 5.5 a) Firma espectral no normalizado (pixel mandarina) ; b) Firma espectral normalizado (pixel mandarina) [Autor].....	50

Figura 5.6 Montaje Experimental para Adquisición de Imágenes Hiperespectrales con la Cámara Specim FX10e. Preparacion de la muestra en la banda transportadora[Autor].....	51
Figura 5.7 Imagen capturada por la cámara Specim FX10e; a) Imagen no Normalizada; b) Imagen Normalizada[Autor].....	52
Figura 5.8 Índices de la matriz del DataCubo[Autor].	53
Figura 6.1 Etapa de la metodología aplicada[Autor].....	55
Figura 6.2 Segmentación de Cítricos[Autor].....	56
Figura 6.3 Objetos Aislados	58
Figura 6.4 Múltiples firmas espectrales de cada mandarina[Autor].....	59
Figura 6.5 (a) Extracción de componentes principales de las firmas espectrales; (b) Selección de las componentes principales con mayor información[Autor].....	60
Figura 6.6 Mapeo de clasificación de muestra por probabilidades[Autor].	65

TABLA DE CONTENIDO

DEDICATORIA	i
AGRADECIMIENTOS	ii
RESUMEN	v
ABSTRACT	vi
1. INTRODUCCIÓN	1
2. OBJETIVOS.....	3
2.1 OBJETIVO GENERAL.....	3
2.2 OBJETIVOS ESPECÍFICOS.....	3
3. ESTADO DEL ARTE	4
4. MARCO TEÓRICO.....	7
4.1 Introducción	7
4.2 Fundamentos Teóricos de las Imágenes Hiperespectrales.....	8
4.2.1 Diferencias entre imágenes espectrales, hiperespectrales y multiespectrales.	10
4.3 Principios de Funcionamiento de las Imágenes Hiperespectrales	11
4.3.1 El espectro electromagnético y su relevancia en la espectroscopía.....	11
4.3.2 Interacción de la luz con la materia: Reflexión, absorción y transmisión.....	14
4.3.3 Creación y análisis del datacubo hiperespectral.....	19
4.3.4 Comparación con otras técnicas de obtención de imágenes.¡Error! Marcador no definido.	
4.4 Configuración de un Sistema de Imágenes Hiperespectrales	22
4.4.1 Elementos principales: Lente de objetivo, dispersor espectral y detector bidimensional.....	22

4.4.2	Modos de adquisición de imágenes: Escaneo de área, escaneo de puntos y escaneo de líneas.....	28
4.4.3	Proceso de calibración y alineación de imágenes hiperespectrales.....	30
4.5	Algoritmos de Procesamiento y Análisis de Imágenes Hiperespectrales	35
4.5.1	Redes neuronales.	35
4.5.2	Red Neuronal Tipo BackPropagation.....	38
4.5.3	Técnicas de reducción de dimensionalidad y selección de características relevantes	39
4.6	Estudios y Casos de Éxito en la Clasificación de Frutos Cítricos	43
5.	Descripción del montaje experimental y registro de datos.....	45
5.1	Descripción General del Sistema	45
5.2	Procedimiento Experimental.....	47
6.	Resultados y Análisis	55
7.	Conclusiones	67
8.	Referencias	69

RESUMEN

Este trabajo presenta el desarrollo e implementación de un sistema basado en imágenes hiperespectrales en el rango visible e infrarrojo cercano (VNIR) y redes neuronales profundas, diseñado para clasificar y evaluar el estado de maduración de frutos cítricos, específicamente mandarinas. Utilizando una cámara hiperespectral Specim FX10e, operando entre 400 y 1000 nm, se capturaron datacubos hiperespectrales que permitieron analizar propiedades internas y externas de los frutos. Las imágenes fueron procesadas mediante técnicas de reducción de dimensionalidad, como el Análisis de Componentes Principales (PCA), para extraer las bandas espectrales más relevantes, preservando el 97% de la información útil en las firmas espectrales.

Para la clasificación, se desarrolló una red neuronal profunda utilizando el algoritmo Levenberg-Marquardt backpropagation, configurada para optimizar la identificación de estados de maduración (verde, pintón y maduro). Este enfoque permitió alcanzar una precisión del 100% en la matriz de confusión, evidenciando la eficacia del sistema en condiciones controladas. La segmentación y selección de bandas específicas (562.4 nm, 750 nm y 951.7 nm) fueron claves para eliminar el ruido y mejorar la discriminación de clases.

Más allá de la aplicación práctica en la clasificación de cítricos, este estudio contribuye significativamente al campo de la espectroscopía hiperespectral y el procesamiento de imágenes al integrar técnicas de aprendizaje profundo y reducción de dimensionalidad con datos espectrales complejos. Los resultados obtenidos demuestran que el análisis hiperespectral combinado con redes neuronales puede superar las limitaciones de métodos tradicionales, proporcionando una solución no destructiva, precisa y escalable para la evaluación de calidad en productos agrícolas.

Este trabajo sienta las bases para futuras investigaciones en el desarrollo de sistemas de clasificación automatizada, no solo en frutos cítricos, sino también en otros productos agrícolas. Además, ofrece un enfoque metodológico robusto que puede ser adaptado a diferentes entornos industriales, impulsando la modernización del control de calidad en la agroindustria.

ABSTRACT

This study presents the development and implementation of a system based on hyperspectral imaging in the visible and near-infrared range (VNIR) and deep neural networks, designed to classify and evaluate the ripening stages of citrus fruits, specifically mandarins. Using a Specim FX10e hyperspectral camera operating between 400 and 1000 nm, hyperspectral datacubes were captured to analyze both internal and external properties of the fruits. The images were processed using dimensionality reduction techniques, such as Principal Component Analysis (PCA), to extract the most relevant spectral bands, retaining 97% of the useful information in the spectral signatures.

For classification, a deep neural network was developed using the Levenberg-Marquardt backpropagation algorithm, configured to optimize the identification of ripening stages (green, partially ripe, and fully ripe). This approach achieved 100% precision in the confusion matrix, demonstrating the system's effectiveness under controlled conditions. Segmentation and selection of specific bands (562.4 nm, 750 nm, and 951.7 nm) were key to noise reduction and improved class discrimination.

Beyond its practical application in citrus fruit classification, this study significantly contributes to the field of hyperspectral spectroscopy and image processing by integrating deep learning and dimensionality reduction techniques with complex spectral data. The results demonstrate that hyperspectral analysis combined with neural networks can overcome the limitations of traditional methods, providing a non-destructive, precise, and scalable solution for quality assessment in agricultural products.

This work lays the foundation for future research in automated classification systems, not only for citrus fruits but also for other agricultural products. Additionally, it offers a robust methodological framework that can be adapted to various industrial environments, driving the modernization of quality control in the agroindustry.

1. INTRODUCCIÓN

La calidad de los productos agrícolas, en particular los frutos cítricos como la mandarina y el limón, es crucial para satisfacer las demandas de un mercado en constante evolución. Estos productos, valorados por su importancia económica y nutricional, requieren métodos de clasificación que garanticen estándares de frescura, madurez y ausencia de defectos. Tradicionalmente, esta inspección se realiza de forma manual, lo que limita la precisión y la eficiencia al depender de evaluaciones subjetivas y a menudo incapaces de detectar defectos internos o variaciones químicas significativas [1].

En los últimos años, las imágenes hiperespectrales han emergido como una herramienta avanzada para analizar alimentos y productos agrícolas. Estas técnicas capturan información espectral en múltiples longitudes de onda, generando un datacubo tridimensional donde cada píxel refleja una firma espectral única. Esto permite identificar atributos internos del fruto, como el contenido de agua y el estado de madurez, que no son visibles a simple vista[2].

Sin embargo, el gran volumen de datos y la complejidad de extraer características relevantes plantean importantes desafíos analíticos[3].

Para superar estas dificultades, los algoritmos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), se han convertido en una solución prometedora. Estas técnicas pueden identificar patrones espectrales complejos de forma automática, optimizando procesos de clasificación en tiempo real [4]. La integración de imágenes hiperespectrales con aprendizaje profundo permite no solo mejorar la eficiencia en la línea de producción, sino también garantizar estándares de calidad más altos [5].

El presente estudio propone desarrollar un sistema de clasificación automática de frutos cítricos basado en imágenes hiperespectrales y redes neuronales. Utilizando datos obtenidos mediante una cámara hiperespectral, se implementará un algoritmo diseñado para identificar y clasificar atributos discriminantes en frutos como las mandarinas de Simacota, Santander, Colombia. Los objetivos específicos incluyen: (1) Crear un conjunto de datos hiperespectrales para la extracción de

características relevantes, (2) Diseñar un sistema de preprocesamiento de imágenes para optimizar la discriminación entre objetos y (3) Implementar una arquitectura de redes neuronales para clasificar los frutos según su estado de maduración.

Este enfoque busca transformar los métodos de clasificación agrícola mediante el uso de tecnologías óptico-computacionales. Al combinar espectroscopía e inteligencia artificial, esta investigación ofrece una metodología automatizada que optimiza procesos tradicionales y contribuye al desarrollo de la agricultura inteligente en regiones como Santander. Así, este trabajo no solo mejora la eficiencia en la clasificación de frutos, sino que también impulsa la investigación en espectroscopía hiperespectral aplicada a la agroindustria.

Este trabajo integra conceptos fundamentales de la Física, como la interacción luz-materia y la espectroscopía, con herramientas modernas de análisis de datos, alineándose con los objetivos formativos del programa de Física al combinar conocimientos teóricos y habilidades prácticas para resolver problemas reales.

2. OBJETIVOS

2.1 OBJETIVO GENERAL

Diseñar e implementar un algoritmo basado en aprendizaje profundo para la sustracción de propiedades y atributos discriminantes de frutos cítricos desde imágenes espectrales VNIR, incluyendo tamaño, color, índices espectrales de vegetación y otros estándares establecidos con los citricultores, que permitan clasificar dichos frutos en tiempo real.

2.2 OBJETIVOS ESPECÍFICOS

- Elaborar un conjunto de registros de cítricos que permitan extraer características y su espectro y clasificarlos manualmente en grupos específicos de calidad.
- Realizar un estudio espectral de las imágenes registradas y conceptualizar un conjunto de operaciones de pre-procesamiento que posibilite una mejor discriminación de los objetos en la escena.
- Diseñar e implementar una arquitectura de red profunda: Basada en redes neuronales (NN) para el entrenamiento, validación y prueba de la red neuronal.

Estos objetivos están alineados con la misión de mejorar la productividad y competitividad de la industria cítrica en el Departamento de Santander, Colombia, integrando conocimientos técnicos y científicos con las prácticas agrícolas tradicionales del territorio.

3. ESTADO DEL ARTE

El estudio del espectro de luz tiene sus raíces en el siglo XVII, cuando Isaac Newton demostró que la luz blanca se descompone en un abanico de colores al atravesar un prisma. Este experimento, realizado en 1666, estableció los fundamentos de la espectroscopía óptica, al mostrar que la luz visible tiene diferentes componentes espectrales[6]. Más adelante, en el siglo XIX, Joseph von Fraunhofer desarrolló los primeros espectroscopios, con los que identificó las primeras líneas de absorción en el espectro solar y mejoró la precisión en la observación espectral [7]. Estos avances consolidaron a la espectroscopia como una disciplina formal, fundamental para el análisis de materiales a través de sus propiedades ópticas.

La tecnología espectroscópica experimentó un gran salto en la segunda mitad del siglo XX, cuando los sensores electrónicos comenzaron a reemplazar a los métodos fotográficos tradicionales. La introducción de dispositivos como los tubos fotomultiplicadores permitió capturar y medir la intensidad de la luz en distintas longitudes de onda con mayor precisión [8]. A continuación, en la década de 1980, la aparición de los dispositivos de carga acoplada (CCD) revolucionó el campo. Estos sensores permitieron el desarrollo de espectrómetros digitales, capaces de capturar datos espectrales de forma rápida y almacenarlos electrónicamente. Los CCD mejoraron la resolución espectral, lo que permitió que la espectroscopia se expandiera a nuevos dominios científicos e industriales [9].

Paralelamente, el interés en la imagen multiespectral surgió con fuerza en la década de 1970, especialmente impulsado por aplicaciones aeroespaciales y de monitoreo terrestre. Organismos como la NASA comenzaron a utilizar generadores de imágenes multiespectrales en satélites para observar y analizar diversas características de la superficie terrestre y capturar información en bandas, como el visible y el infrarrojo [11]. Estos desarrollos marcaron un antes y un después en el estudio ambiental y geoespacial, permitiendo obtener información detallada sobre la vegetación, el suelo y los cuerpos de agua.

A finales de la década de 1980, la tecnología hiperespectral emergió como una extensión avanzada de la multiespectral. Los sistemas hiperespectrales se diferencian de los multiespectrales por capturar cientos de bandas espectrales de manera continua, lo cual permite una discriminación precisa de los materiales observados, así como la detección de diferencias sutiles en sus propiedades ópticas [12]. Esta innovación inicial permitió la creación de los primeros espectrómetros de imágenes hiperespectrales, con aplicaciones que iban desde la agricultura de precisión hasta la seguridad y la prospección geológica.

A medida que estas tecnologías se expandieron, surgieron técnicas de procesamiento de datos como la clasificación espectral y el análisis de componentes principales (PCA), que optimizaron la extracción de información en imágenes hiperespectrales y multiespectrales. Estos métodos permiten obtener una caracterización detallada de los materiales observados, y con la reciente inclusión de herramientas de inteligencia artificial y aprendizaje automático, se ha alcanzado un nuevo nivel de precisión en el análisis de datos espectrales [10].

En la actualidad, la imagen multiespectral se aplica principalmente en la agricultura de precisión, la gestión de recursos hídricos y el manejo forestal, mientras que las imágenes hiperespectrales se emplean ampliamente en diagnósticos médicos, detección geológica y control de calidad industrial [11]. Las aplicaciones y metodologías en espectroscopia e imágenes multiespectrales e hiperespectrales siguen evolucionando, reforzando su papel como herramientas cruciales en la investigación y el monitoreo de recursos naturales y procesos industriales.

En las últimas décadas, diversas técnicas han sido exploradas como posibles métodos instrumentales para la evaluación de la calidad de productos alimentarios. Recientemente, la técnica de imágenes hiperespectrales ha sido reconocida como una herramienta analítica prometedora para análisis en investigación, control e industria. Las imágenes hiperespectrales generan un mapa espacial de variación espectral, lo que las hace útiles en múltiples aplicaciones. La técnica combina métodos espectroscópicos y de imagen, generando un conjunto de datos

tridimensional, conocido como datacubo o hipercubo, que contiene dos dimensiones espaciales y una espectral [12], [13], [14], [15].

Debido a las crecientes expectativas de productos alimentarios de alta calidad y seguridad, la necesidad de métodos precisos, rápidos y objetivos para determinar estas características continúa en aumento. La automatización de la evaluación de calidad no solo optimiza el aseguramiento de la misma, sino que también contribuye a eliminar la subjetividad humana y las inconsistencias, aumentando la productividad y transformando el trabajo en una labor menos ardua y más atractiva [16].

La espectroscopía se basa en la interacción de la radiación electromagnética con átomos y moléculas para proporcionar información química y física cualitativa y cuantitativa. Las técnicas espectroscópicas en el infrarrojo cercano (NIRS) han ganado considerable atención debido a su capacidad para medir múltiples atributos de calidad de forma rápida y no destructiva. Sin embargo, la combinación de técnicas espectroscópicas con técnicas de visión han dado lugar a la hiperespectroscopía, la cual supera las limitaciones de ambas y se ha convertido en una técnica poderosa para los sistemas agrícolas y alimentarios [17].

Las imágenes hiperespectrales ofrecen varias ventajas, como la ausencia de necesidad de preparación de muestras, su carácter no invasivo y la capacidad de determinar múltiples constituyentes simultáneamente en una muestra. Sin embargo, también presentan desventajas como la gran cantidad de datos generados y los desafíos computacionales asociados. Además, requieren procedimientos de calibración y transferencia de modelos estandarizados para ser efectivas en aplicaciones industriales [18].

4. MARCO TEÓRICO

4.1 Introducción

Los frutos cítricos, como la naranja, el limón y la toronja, desempeñan un papel fundamental en la economía agrícola global debido a su alta demanda tanto para el consumo fresco como para la transformación industrial. La calidad de los frutos cítricos es fundamental para satisfacer los estándares del mercado y las expectativas del consumidor; esta calidad está determinada por factores como el tamaño, el color, la frescura y la ausencia de defectos externos o internos [19].

El control de calidad se ha realizado tradicionalmente a través de inspecciones manuales, las cuales dependen de la observación visual del inspector. Sin embargo, este método presenta varias limitaciones, como la subjetividad, variabilidad entre inspectores y la imposibilidad de detectar defectos internos. Debido a estos desafíos, se han desarrollado tecnologías no destructivas, como las imágenes hiperespectrales, que permiten un análisis más profundo y preciso de los atributos de calidad, identificando defectos visibles e internos, mejorando así la precisión y la eficiencia del proceso de clasificación [20].

La tecnología de imágenes hiperespectrales combina la espectroscopía y la adquisición de imágenes, que captura información a lo largo de un rango continuo de longitudes de onda para cada píxel de la imagen. Esto genera un datacubo hiperespectral, que proporciona información tanto espacial como espectral detallada de los objetos. Esta tecnología resulta útil en la agricultura, ya que permite evaluar características internas de los frutos, como su composición química y posibles defectos no visibles a simple vista [21].

En el contexto de la clasificación de frutos cítricos, las imágenes hiperespectrales permite detectar defectos tales como enfermedades, daños por impacto o variaciones en la madurez. La capacidad de la tecnología para adquirir imágenes en el rango espectral del visible e infrarrojo cercano (VNIR) permite una evaluación precisa de la calidad sin necesidad de realizar cortes o manipulaciones destructivas en los frutos [22].

Además, mediante el uso de algoritmos avanzados, como redes neuronales, es posible realizar una clasificación automática y rápida de los frutos, optimizando tanto el tiempo como la precisión en el proceso de control de calidad.




Figura 4.1 Una red neuronal artificial multicapa[Autor].

La figura 4.1 muestra una red neuronal artificial multicapa utilizada en la clasificación de imágenes hiperespectrales; esta ilustra cómo los sistemas automáticos procesan la información para clasificar los frutos cítricos en función de sus atributos espectrales.

4.2 Fundamentos Teóricos de las Imágenes Hiperespectrales

La espectroscopía tiene sus raíces en los experimentos sobre la dispersión de la luz de Isaac Newton en el siglo XVII. En el siglo XIX, Fraunhofer y Kirchhoff profundizaron en este campo al descubrir que las líneas espectrales eran indicativas de elementos químicos, lo que llevó a la creación de la espectroscopía moderna. Con el tiempo, esta técnica se ha aplicado en una variedad de campos, incluido el análisis de alimentos y productos agrícolas. En la segunda mitad del siglo XX, las aplicaciones en agricultura aumentaron significativamente, con el uso de la espectroscopía de infrarrojo cercano (NIR) para evaluar la calidad de productos sin destruir la muestra [4].

En la actualidad, la espectroscopía hiperespectral ha evolucionado como una herramienta poderosa que permite obtener información detallada tanto externa como interna de productos como los frutos

cítricos, lo que es de gran utilidad para la clasificación y evaluación de calidad en la industria agrícola [21].

La espectroscopía estudia la interacción de la luz con la materia, permitiendo obtener firmas espectrales únicas para cada objeto según cómo refleje, absorba o transmita la luz en diferentes longitudes de onda [4]. En las imágenes hiperespectrales, este principio se aplica capturando datos espectrales en cientos de bandas estrechas, generando un datacubo hiperespectral, lo que permite analizar la composición química y las características físicas de un objeto, como un fruto cítrico, en cada píxel de la imagen [23].

Para medir la reflectancia espectral de un objeto, se utiliza la fórmula siguiente:

$$R(\lambda) = \frac{I_r(\lambda)}{I_0(\lambda)} \quad (4.1)$$

Donde:

$R(\lambda)$ es la reflectancia en una longitud de onda particular λ .

$I_r(\lambda)$ es la intensidad de luz reflejada por el objeto.

$I_0(\lambda)$ es la intensidad de luz incidente.

La ecuación 4.1 es esencial para describir cómo se mide la interacción de la luz con los frutos cítricos y se utiliza para detectar defectos internos que no son visibles a simple vista, como podemos representar conceptualmente en la figura 4.2.




Figura 4.2 Interacción de la Luz con la Materia: Ejemplo de Reflectancia en un Tomate[Autor].

4.2.1 Diferencias entre imágenes espectrales, hiperespectrales y multiespectrales.

Las imágenes espectrales son aquellas que registran información en distintas longitudes de onda, divididas en dos categorías principales: multiespectrales e hiperespectrales. Las imágenes multiespectrales capturan un número limitado de bandas espectrales (entre 3 y 10), separadas por intervalos amplios y centradas en longitudes clave, como el visible (RGB) y el infrarrojo cercano (NIR). Por otro lado, las imágenes hiperespectrales recopilan datos en un rango continuo de más de 100 bandas espectrales, permitiendo una caracterización detallada de cada píxel en términos de su firma espectral[24] [25].

En comparación, las imágenes RGB, aunque útiles para evaluar propiedades visibles como el color y la textura, son insuficientes para detectar defectos internos o variaciones químicas. Las imágenes multiespectrales, al incluir bandas adicionales en el infrarrojo, permiten un análisis más profundo de ciertas propiedades internas. Sin embargo, las imágenes hiperespectrales destacan por su capacidad de detectar variaciones sutiles y no visibles, gracias a su resolución espectral superior.

Esta ventaja las convierte en una herramienta ideal para aplicaciones avanzadas como la evaluación de calidad en frutos cítricos[21].




Figura 4.3 Comparación de tipo de imágenes de acuerdo a la cantidad de longitudes de onda registradas[Autor].

En la figura 4.3 podemos ver las imágenes hiperespectrales ofrecen una ventaja significativa sobre las otras técnicas de obtención de imágenes debido a su capacidad para capturar un rango completo de longitudes de onda, lo que permite un análisis detallado tanto de la superficie como del interior de los frutos cítricos. Mientras que las imágenes RGB y multiespectrales se centran en un número limitado de bandas, las imágenes hiperespectrales proporcionan información integral que es esencial para una evaluación precisa de la calidad y detección de defectos en productos agrícolas.

4.3 Principios de Funcionamiento de las Imágenes Hiperespectrales

4.3.1 El espectro electromagnético y su relevancia en la espectroscopía.

El espectro electromagnético es fundamental para comprender el funcionamiento de las imágenes hiperespectrales. Este espectro describe la gama completa de radiación electromagnética, desde las ondas de radio de baja energía hasta los rayos gamma de alta energía, e incluye la luz visible, el infrarrojo cercano (NIR), y el ultravioleta (UV), entre otras (ver figura 4.4). Las longitudes de onda varían entre 1 nm (rayos gamma) hasta kilómetros de longitud (ondas de radio largas) [4].




Figura 4.4 Espectro Electromagnético[26].

Dentro de este espectro, la espectroscopía se enfoca en cómo los objetos interactúan con diferentes longitudes de onda de luz, es decir, cómo absorben, transmiten o reflejan radiación electromagnética en diferentes partes del espectro. Esta interacción genera lo que se conoce como una firma espectral única, la cual puede ser utilizada para identificar la composición química o la estructura física del objeto. En el caso de los frutos cítricos, esta información espectral puede revelar características como el contenido de agua, azúcares, defectos internos y posibles enfermedades [23].

El uso de imágenes hiperespectrales en agricultura, especialmente en frutos cítricos, se centra principalmente en las longitudes de onda del visible (400–700 nm) y el infrarrojo cercano (NIR) (700–2500 nm) (ver figura 4.5). Estas longitudes de onda son particularmente útiles porque la luz visible permite analizar las características externas (como el color y la textura), mientras que el NIR permite detectar propiedades internas, como la estructura celular y la concentración de compuestos químicos. La combinación de estas longitudes de onda proporciona una imagen completa del estado de los frutos cítricos, tanto interna como externamente [21].




Figura 4.5 Clasificación del Espectro Visible e Infrarrojo: Divisiones en Infrarrojo Cercano (NIR), Medio (Mid IR) y Lejano (Far IR) con sus rangos de longitud de onda[27].

Para ilustrar la relación entre diferentes longitudes de onda y sus aplicaciones en la clasificación de frutos cítricos, se presenta en la tabla 1.1 la descripción de las principales regiones del espectro electromagnético utilizadas en la espectroscopía hiperespectral:

Tabla 1.1: descripción de las principales regiones del espectro electromagnético utilizadas en la espectroscopía hiperespectral.

Región del espectro	Longitud de onda	Aplicación en frutos cítricos
Visible (VIS)	400 – 700 nm	Evaluación de color, textura y daños superficiales.
Infrarrojo Cercano (NIR)	700 – 2500 nm	Detección de defectos internos, contenido de agua
Infrarrojo Medio (MIR)	2500 - 5000 nm	Evaluación de compuestos químicos específicos

La importancia del espectro electromagnético en las imágenes hiperespectrales radica en que cada longitud de onda ofrece información diferente. Mientras que las imágenes en el espectro visible permiten a los sistemas detectar defectos externos visibles, las imágenes en el infrarrojo cercano proporcionan información más profunda, como la detección de daños internos, niveles de madurez o la presencia de enfermedades [28].




Figura 4.6 Diagrama esquemático de un hipercubo de imagen hiperespectral para una pieza de carne que muestra la relación entre la información espectral y espacial en tres dimensiones[29].

En la figura 4.6 se puede ver que cada píxel en la imagen hiperespectral está representado por un espectro individual que contiene información sobre la composición química en esa posición específica del espacio. El espectro electromagnético resalta las áreas clave del espectro que se utilizan en la espectroscopía hiperespectral, proporcionando una visión clara de cómo las diferentes longitudes de onda contribuyen al análisis de calidad en productos agrícolas.

Aunque en este caso la figura 4.6 se refiere a un análisis de carne, el concepto es aplicable a cualquier producto agrícola, incluidos los frutos cítricos.

4.3.2 Interacción luz-materia en el rango VNIR: Reflexión, absorción y transmisión y dispersión

La interacción de la radiación electromagnética con la materia en el rango visible e infrarrojo cercano (VNIR) constituye una herramienta fundamental para la caracterización no destructiva de frutos cítricos. Este rango espectral (400–1000 nm) permite analizar propiedades tanto externas

como internas de los frutos a partir de los fenómenos de reflexión, absorción, transmisión y dispersión [4].

Absorción de la Luz

La absorción ocurre cuando la energía de la radiación electromagnética incidente es capturada por las moléculas del material, generando transiciones electrónicas, vibracionales o rotacionales dependiendo de la longitud de onda. En los frutos cítricos, la absorción está directamente asociada a los componentes químicos presentes, como los pigmentos (clorofila, carotenoides) y el contenido de agua. Por ejemplo, los pigmentos como la clorofila absorben en las regiones azul (~450 nm) y roja (~680 nm), mientras que reflejan en la región verde (~550 nm), otorgando el color característico a los frutos. En el rango infrarrojo cercano, las moléculas de agua presentan bandas de absorción específicas alrededor de 970 nm, utilizadas para evaluar su contenido de humedad [30].

Es fenómeno es descrito por la Ley de Beer-Lambert[31].

$$A(\lambda) = -\log\left(\frac{I_t(\lambda)}{I_0(\lambda)}\right) = \varepsilon(\lambda) \cdot c \cdot l \quad (4.2)$$

Donde:

$A(\lambda)$ es la absorbancia a una longitud de onda λ .

$I_t(\lambda)$ es la intensidad transmitida.

$I_0(\lambda)$ es la intensidad de luz incidente.

$\varepsilon(\lambda)$ es el coeficiente de absorción molar.

c es la concentración del material.

l es el espesor del material.

Reflexión de la Luz

La reflexión ocurre cuando la radiación electromagnética incidente es redirigida por la superficie del objeto. Este fenómeno puede dividirse en:

Reflexión especular, donde la luz se refleja en un ángulo igual al de incidencia sobre superficies lisas.

Reflexión difusa, resultado de la interacción con superficies rugosas o heterogéneas, redirigiendo la luz en múltiples direcciones.

En frutos cítricos, la reflectancia difusa es relevante, ya que la textura de la superficie del fruto dispersa la luz reflejada, permitiendo obtener información sobre la composición química y los defectos superficiales. Matemáticamente, la reflectancia ($R(\lambda)$) se expresa como la ecuación 4.1[32].

Transmisión de la Luz

La transmisión describe el paso de la radiación a través del material sin ser absorbida ni reflejada. Este fenómeno depende de las propiedades ópticas del medio y de la longitud de onda de la luz incidente. En los frutos cítricos, la transmitancia ($T(\lambda)$) es utilizada para evaluar la estructura interna, permitiendo identificar daños o descomposición no visibles externamente. Su relación matemática es [33]:

$$T(\lambda) = \frac{I_t(\lambda)}{I_0(\lambda)} \quad (4.3)$$

Donde:

$T(\lambda)$ es la transmitancia a una longitud de onda λ .

$I_t(\lambda)$ es la intensidad de la luz transmitida.

$I_0(\lambda)$ es la intensidad de luz incidente.

Dispersión de la Luz

La dispersión fue observada por primera vez por los antiguos griegos, pero fue Isaac Newton en el siglo XVII quien realizó experimentos fundamentales al pasar luz solar a través de un prisma. Newton descubrió que la luz blanca se descompone en un espectro de colores y postuló que la dispersión ocurre debido a la dependencia de la refracción con la longitud de onda. Posteriormente

en el siglo XIV, científicos como Augustin Fresnel y Hermann von Helmholtz ampliaron la comprensión de este fenómeno, vinculándolo con la naturaleza ondulatoria de la luz. En el siglo XX Albert Einstein y C.V. Raman estudiaron efectos más específicos de dispersión relacionados con las interacciones cuánticas entre luz y materia.

La dispersión de la luz, se define como el fenómeno que permite la separación o descomposición de las longitudes de onda constituyentes de un haz luminoso. Con los avances en la óptica y la espectroscopía, este conocimiento se ha traducido en aplicaciones que van desde la investigación básica hasta tecnologías aplicadas, como sensores espectrales y analizadores de luz.

La dispersión de la luz ocurre debido a la dependencia de la velocidad de propagación con la longitud de onda dentro de un medio material. Este fenómeno da lugar a efectos como el arcoíris y permite descomponer la luz blanca en su espectro de colores. Los principales mecanismos de dispersión incluyen:

Dispersión cromática: Es un fenómeno óptico que ocurre cuando un haz de luz policromática (compuesta por múltiples longitudes de onda) se descompone en sus diferentes componentes espectrales al atravesar un medio dispersivo, como un prisma, una lente, una rejilla de difracción o una fibra óptica. Este fenómeno surge debido a que el índice de refracción de un material depende longitud de onda de la luz, lo que provoca que las diferentes longitudes de onda viajen a velocidades distintas y se desvíen en ángulos diferentes.

Dispersión de Rayleigh Este fenómeno que ocurre cuando la luz atraviesa un medio líquido o gaseoso compuesto de moléculas o partículas en suspensión. Esta dispersión se da cuando las partículas que dispersan la luz son mucho más pequeñas que la longitud de onda. Este fenómeno permite explicar el color azul del cielo, ya que la luz azul, con longitudes de onda más cortas, se dispersa más que la roja.

La intensidad de la luz dispersada es inversamente proporcional a λ^4 .

$$I(\theta) = I_0 \cdot \frac{8\pi^4 \cdot \alpha^2}{\lambda^4} \cdot \frac{1 + \cos^2 \theta}{R^2} \quad (4.4)$$

Donde:

$I(\theta)$: Intensidad de la luz dispersada en un ángulo θ .

I_0 : Intensidad de la luz incidente.

α : Polarizabilidad de la partícula.

λ : Longitud de onda de la luz incidente.

θ : Ángulo de dispersión.

R : Distancia desde la partícula al punto de observación.

$8\pi^4$: Constante derivada de la relación entre la dispersión y las propiedades ópticas.

En la ecuación 4.4 muestra que la intensidad de la luz dispersada es inversamente proporcional a la cuarta potencia de la longitud de onda λ^4 , lo que explica por qué la luz azul (longitud de onda más corta) se dispersa más que la roja (longitud de onda más larga).

Dispersión de Mie: Este fenómeno también ocurre cuando la luz atraviesa un medio líquido o gaseoso compuesto de moléculas o partículas en suspensión. Pero, esta dispersión se da cuando las partículas tienen tamaños comparables a la longitud de onda de la luz. La dispersión de Mie es responsable del color blanco de las nubes. Se da cuando las partículas tienen dimensiones comparables a la longitud de onda incidente. Es predominante en frutos cítricos, donde las células y las interfaces entre tejidos actúan como centros dispersores.

En el contexto de frutos cítricos, la dispersión de Mie predomina debido al tamaño de las células, afectando la intensidad y el patrón de propagación de la luz dentro del fruto[34].

La aplicación de estos fenómenos en imágenes hiperespectrales permite extraer propiedades discriminantes de los frutos cítricos, como el contenido de agua (relacionado con la absorción en el infrarrojo cercano), el estado superficial (reflexión difusa en el visible) y los defectos internos (transmisión y dispersión). La dispersión de Mie, en particular, proporciona información valiosa sobre la microestructura interna del fruto[35].

4.3.3 Creación y análisis del datacubo hiperspectral.

La creación del datacubo hiperspectral es el proceso clave que permite obtener imágenes espectrales de alta resolución en múltiples longitudes de onda. El datacubo hiperspectral contiene tres dimensiones: dos dimensiones espaciales (x, y) que representan la imagen convencional del objeto y una tercera dimensión (λ) que representa las longitudes de onda, capturando información espectral en cada píxel. Cada píxel del datacubo contiene una firma espectral única que proporciona información detallada sobre la composición física y química del objeto analizado.

La adquisición de imágenes hiperspectrales se realiza mediante sistemas ópticos avanzados que capturan la luz reflejada o transmitida por un objeto en varias bandas del espectro electromagnético.

Después de capturar las imágenes en diferentes longitudes de onda, los datos se organizan en un datacubo (x, y, λ) (ver figura 4.7), donde cada píxel contiene un espectro completo de longitudes de onda que describen cómo el objeto interactúa con la luz en esa ubicación [15].




Figura 4.7 Representaciones conceptuales de los modos de adquisición de imágenes. (a) Modo de escaneo por longitud de onda; (b) Modo de escaneo[36].

El análisis del datacubo hiperspectral implica procesar la información espacial y espectral para extraer características relevantes del objeto. Este análisis se lleva a cabo utilizando varias técnicas, que incluyen:

- *Clasificación espectral*: Se asignan etiquetas a los píxeles del datacubo basándose en las similitudes en sus firmas espectrales. Los algoritmos de clasificación, como las redes neuronales o los métodos basados en aprendizaje automático, son fundamentales para

identificar características específicas de los frutos cítricos, como la presencia de defectos o el nivel de madurez.

- *Reducción de dimensionalidad:* Debido a que los datacubos hiperespectrales pueden contener cientos de bandas espectrales, el manejo de estos datos puede ser costoso en términos computacionales. Métodos como el Análisis de Componentes Principales (PCA) o el Análisis de Componentes Independiente (ICA) se utilizan para reducir la dimensionalidad del datacubo, preservando la información más relevante mientras se disminuye el tamaño de los datos [28].
- *Extracción de características:* Este proceso implica seleccionar las longitudes de onda más informativas para una tarea específica, como la detección de enfermedades o defectos internos en frutos. Las bandas espectrales seleccionadas pueden correlacionarse con la concentración de compuestos químicos o la presencia de anomalías físicas.

En el análisis del datacubo, una técnica común es la aplicación del Análisis de Componentes Principales (PCA). La fórmula básica para PCA es:

$$Z = W^T \cdot X \quad (4.5)$$

Dónde:

Z es el conjunto de datos transformados (componentes principales).

W es la matriz de pesos (autovectores de la matriz de covarianza).

T es la transpuesta de la matriz W

X es el conjunto de datos originales (el datacubo en este caso).




Figura 4.8 Diferentes imágenes del mismo fruto afectado por moho verde en luz visible, infrarrojo cercano, fluorescencia e iluminación ultravioleta[37].

Este proceso transforma los datos del datacubo en un nuevo espacio de menor dimensionalidad, facilitando la identificación de las características más relevantes.

En caso de los frutos cítricos, la generación del datacubo hiperespectral permite capturar información sobre la superficie y el interior del fruto. Las imágenes en el espectro visible pueden detectar defectos externos como manchas o decoloraciones, mientras que las imágenes en el infrarrojo cercano (NIR) proporcionan información sobre la estructura interna y el contenido de agua del fruto. El análisis del datacubo puede ayudar a clasificar los frutos en diferentes categorías de calidad, detectar enfermedades y evaluar el nivel de madurez [38]. En la figura 4.8 muestra cómo se puede utilizar información hiperespectral para detectar defectos en los frutos, como la aparición de moho en los cítricos.

4.4 Configuración de un Sistema de Imágenes Hiperespectrales

4.4.1 Elementos principales: Lente de objetivo, dispersor espectral y detector bidimensional.

Un sistema de imágenes hiperespectrales está compuesto por varios elementos clave que permiten capturar información espectral y espacial de un objeto. Cada uno de estos componentes juega un papel crucial en el proceso de adquisición de imágenes hiperespectrales, facilitando la obtención de un datacubo hiperespectral que contiene información detallada sobre el objeto a lo largo de diversas longitudes de onda.

- *Lente de objetivo:* El lente de objetivo es el componente responsable de enfocar la luz que proviene del objeto hacia el sistema óptico. La función principal del lente es capturar la imagen del objeto y proyectarla hacia el dispersor espectral. Este elemento óptico debe estar optimizado para trabajar en un amplio rango de longitudes de onda, desde el espectro visible hasta el infrarrojo cercano (VNIR).

En los sistemas hiperespectrales, es crucial que el lente mantenga una alta calidad de enfoque en todo el rango espectral para asegurar que la información de cada banda de longitud de onda sea capturada con precisión [39]. La calidad del lente afecta directamente la resolución espacial y espectral del sistema, por lo que se utilizan lentes especializados que minimizan la distorsión y la aberración cromática.

- *Dispersor espectral:* El dispersor espectral es el componente clave que descompone o separa la luz incidente en sus diferentes longitudes de onda. Existen diferentes tipos de dispersores que se utilizan comúnmente en los sistemas de imágenes hiperespectrales:
 - *Prismas:* Un prisma óptico actúa como un dispersor espectral debido a la dispersión cromática, el cual separa o descompone la luz en sus longitudes de onda constituyentes mediante la refracción, haciendo que cada longitud de onda dependa del índice de refracción del medio (ver figura 4.9 (a)). En este fenómeno el índice de refracción (n) varía con la longitud de onda (λ) de la luz incidente. Este efecto es explicado por la fórmula de Cauchy:

$$n(\lambda) = A + \frac{B}{\lambda^2} + \frac{C}{\lambda^4} \quad (4.6)$$

Donde:

A, B y C son coeficientes característicos del material, λ es la longitud de onda de la luz incidente.

La desviación angular (δ) de un prisma se determina por:

$$\delta = (\phi - \theta_1 - \theta_2) \quad (4.7)$$

Donde:

ϕ : ángulo del prisma.

θ_1 y θ_2 : ángulos de incidencia y refracción.

Aunque los prismas fueron fundamentales en espectroscopios clásicos, en sistemas hiperspectrales modernos presentan limitaciones en la resolución espectral y su uso es menos común. Sin embargo, su capacidad para generar una dispersión continua y uniforme los hace útiles en aplicaciones específicas [4].

- *Redes de difracción:* Las redes de difracción son fundamentales en la espectroscopía moderna, permiten una separación precisa de longitudes de onda mediante el fenómeno de la difracción y la interferencia. Estas son los dispersores espectrales más utilizados en sistemas hiperspectrales debido a su alta resolución espectral y precisión en la separación de longitudes de onda específicas (ver figura 4.9 (b)). Las redes de difracción están conformadas por superficie de forma específica y periódica con surcos finamente espaciados.

La dispersión espectral se describe mediante la ecuación de la red:

$$d \cdot (\sin \theta_m + \sin \theta_i) = m \cdot \lambda \quad (4.8)$$

Donde:

d es el espaciamiento de las líneas de la red.

θ_m es el ángulo de difracción para el orden m .

θ_i es el ángulo de incidencia de la luz.

λ es la longitud de onda.

La utilización de redes de difracción facilita la generación de datacubos hiperespectrales de alta calidad al separar múltiples bandas espectrales de manera precisa y simultánea. Esto las hace indispensables en aplicaciones hiperespectrales modernas[30].

- *Dispersor Óptico PGP (Prism-Grating-Prism)*: El dispersor óptico PGP combina las ventajas de los prismas y las redes de difracción, superando muchas de las limitaciones de estos cuando se usan de manera independiente. Este dispositivo integra una red de difracción entre dos prismas ópticos, aprovechando las propiedades de ambos elementos (ver figura 4.9 (c)):

Prismas: Aumentan la dispersión inicial de la luz y ajustan el ángulo de incidencia sobre la red.

Red de Difracción: Proporciona una alta resolución espectral mediante la separación precisa de longitudes de onda específicas.

Ventajas del PGP:

1. Combina alta eficiencia óptica con una resolución espectral sobresaliente.
2. Permite el diseño de sistemas hiperespectrales más compactos y ligeros.

El PGP es ampliamente utilizado en sistemas hiperespectrales modernos, especialmente en aplicaciones portátiles y sistemas de adquisición embarcados. Su capacidad para proporcionar un rendimiento óptico equilibrado entre resolución y eficiencia lo hace ideal para sistemas como el desarrollado en este proyecto[40].

El uso del PGP en este proyecto resulta ventajoso para la generación de datacubos espectrales con alta resolución, manteniendo la eficiencia óptica necesaria para aplicaciones de análisis de calidad en frutos cítricos.

En el sistema diseñado para este trabajo, el dispersor óptico PGP desempeña un papel crucial. Su integración permite una separación espectral precisa, fundamental para identificar las características discriminantes de los frutos cítricos. Esta elección tecnológica asegura un balance óptimo entre resolución, eficiencia y portabilidad del sistema.




Figura 4.9 a) Dispersión de la luz mediante un prisma; b) Difracción de la luz con una red de difracción; c) Sistema híbrido PGP (Prisma-Red de Difracción-Prisma) mostrando la separación de longitudes de onda.[Autor]

- *Detector bidimensional:* El detector bidimensional es la pieza final del sistema de adquisición de imágenes hiperespectrales. Este detector captura la luz que ha sido dispersada por el prisma o la red de difracción, registrando la imagen de cada longitud de onda en los píxeles correspondientes. Los detectores utilizados en sistemas hiperespectrales suelen ser sensores de imagen CCD (Charge-Coupled Device) o CMOS (Complementary Metal-Oxide-Semiconductor) (ver figura 4.10), que pueden captar la luz en el rango visible e infrarrojo cercano [39].

Las cámaras CCD se caracterizan por su alta sensibilidad a la luz y un bajo nivel de ruido, lo que las convierte en herramientas óptimas para aplicaciones que demandan precisión espectral y gran detalle. Su rango típico de sensibilidad espectral abarca desde los 400 nm (azul) hasta los 1000 nm (infrarrojo cercano), como se muestra en la figura 4.10. Son particularmente adecuadas para mediciones hiperespectrales en aplicaciones como el análisis de frutas y vegetales, donde la calidad de la imagen es crucial.

Por otro lado, las cámaras CMOS ofrecen una sensibilidad espectral comparable, cubriendo generalmente el mismo rango de 400 nm a 1000 nm (ver figura 4.10). Sin embargo, destacan por su mayor velocidad y eficiencia energética, lo que las hace especialmente útiles en aplicaciones que requieren procesamiento rápido, como el escaneo en tiempo real de frutas en líneas de producción. Aunque su calidad de imagen puede ser ligeramente inferior a la de las cámaras CCD, su rendimiento en términos de rapidez y consumo energético compensa esta diferencia en muchos contextos prácticos.




Figura 4.10 Sensores CCD y CMOS[Autor].

Los detectores CCD son muy sensibles a la luz y proporcionan una excelente calidad de imagen, mientras que los detectores CMOS son más rápidos y consumen menos energía. La elección del tipo de detector depende de la aplicación específica y del rango espectral que se desea cubrir.

El detector bidimensional es el encargado de generar las imágenes para cada longitud de onda, registrando el resultado en el datacubo. Cada píxel del detector captura una intensidad de luz para una longitud de onda específica, lo que permite reconstruir la imagen espectral completa del objeto (ver figura 4.11) [4].




Figura 4.11 Principio de funcionamiento del espectrógrafo de prisma-rejilla-prisma (PGP) (cortesía de Specim Ltd)[41]

En la evaluación de la calidad de los frutos cítricos mediante imágenes hiperespectrales, el sistema completo lente, dispersor espectral y detector bidimensional permite capturar imágenes a diferentes longitudes de onda, desde el visible hasta el infrarrojo cercano. Esto hace posible identificar defectos externos (como decoloraciones o daños en la piel) y características internas (como el contenido de agua o la presencia de enfermedades), proporcionando una evaluación completa de la calidad del fruto.

4.4.2 Modos de adquisición de imágenes: Escaneo de área, escaneo de puntos y escaneo de líneas.

La adquisición de imágenes hiperespectrales puede realizarse de diferentes formas, dependiendo de las características del sistema y del objeto que se está analizando. Los modos más comunes de adquisición son el escaneo de área, el escaneo de puntos y el escaneo de líneas. Cada uno de estos modos tiene sus ventajas y desventajas, lo que determina su aplicación en diversos escenarios.

- *Escaneo de área (Filtrado espectral)*: El escaneo de área, también conocido como filtrado espectral, es un modo de adquisición en el cual se capturan todas las longitudes de onda de una escena completa en un solo instante. En este modo, el sistema adquiere simultáneamente tanto la información espectral como la espacial de toda la imagen, lo que lo convierte en el método más rápido para la obtención de imágenes hiperespectrales.

El escaneo de área ofrece ventajas como velocidad y adquisición sin movimiento, ideal para aplicaciones en tiempo real y objetos estáticos. Sin embargo, presenta desventajas como menor resolución espectral y requerimiento de hardware especializado y costoso[42].

En la industria agrícola, el escaneo de área puede ser útil en líneas de clasificación automatizadas de frutos cítricos, donde se requiere la captura rápida de imágenes espectrales de múltiples frutos mientras pasan por una cinta transportadora. Esto permite clasificar los frutos en función de su calidad sin detener el proceso productivo.

- *Escaneo de puntos (Point Scanning)*: En el escaneo de puntos, el sistema captura un píxel a la vez, obteniendo la firma espectral completa de ese punto antes de pasar al siguiente.

Este método es más detallado y preciso, ya que permite ajustar la captura de datos espectrales de manera más fina.

El método de adquisición puntual ofrece ventajas como alta resolución espectral y precisión en el análisis, ideal para estudios detallados de composición química y detección de defectos internos. Sin embargo, también presenta desventajas como lentitud y dificultad en el procesamiento de datos [43].

El escaneo de puntos podría ser útil en situaciones donde se requiere un análisis extremadamente detallado de áreas específicas del fruto, como la detección de enfermedades o análisis químico preciso en laboratorios de control de calidad, donde la velocidad no es un factor crucial.

- *Escaneo de líneas (Pushbroom)*: El escaneo de líneas, también conocido como pushbroom, es el modo más común de adquisición en sistemas hiperespectrales. En este método, el sistema captura una línea del área de interés a la vez, registrando la información espectral a lo largo de esa línea, mientras el objeto o la cámara se mueve (ver figura 4.12 y 4.13(b)). Este modo combina las ventajas del escaneo de área y el escaneo de puntos.

El escaneo lineal combina velocidad y resolución espectral, lo que lo hace ideal para aplicaciones prácticas, especialmente con objetos en movimiento. Sin embargo, requiere movimiento y precisa alineación para funcionar correctamente [44].

El escaneo de líneas es el método más adecuado para la clasificación de frutos cítricos en líneas de procesamiento industrial. A medida que los frutos pasan por la línea de producción, el sistema hiperespectral puede capturar información espectral de cada fruto, identificando defectos internos y externos en tiempo real sin necesidad de detener el flujo de trabajo.




Figura 4.12 Esquema de sistema pushbroom incorporado en una banda transportadora[Autor].

Cada uno de los modos de adquisición tiene sus ventajas y desventajas, dependiendo de la aplicación. Para la clasificación y evaluación de frutos cítricos en líneas de producción, el escaneo de líneas (Pushbroom) es el más utilizado debido a su capacidad para capturar información espectral de manera rápida y precisa. Sin embargo, para análisis más detallados o en situaciones de laboratorio, el escaneo de puntos puede proporcionar mayor precisión espectral, mientras que el escaneo de área es más útil en aplicaciones en tiempo real donde la velocidad es crítica.

4.4.3 Proceso de calibración y alineación de imágenes hiperespectrales.

El proceso de calibración y alineación es crucial para garantizar que los datos adquiridos por un sistema de imágenes hiperespectrales sean precisos, reproducibles y de alta calidad. La calibración se refiere a la corrección de las imágenes espectrales para eliminar distorsiones causadas por el sistema de adquisición, mientras que la alineación asegura que las imágenes obtenidas en diferentes longitudes de onda estén correctamente registradas espacialmente.

Calibración radiométrica: La calibración radiométrica es el proceso mediante el cual se ajusta la respuesta espectral del sistema de captura de imágenes para que las intensidades medidas en cada píxel sean precisas y comparables a valores de referencia conocidos. Esto es especialmente

importante en sistemas hiperspectrales, ya que pequeños errores en la intensidad de los datos pueden afectar drásticamente la precisión del análisis espectral.




Figura 4.13 Arquitecturas tradicionales de adquisición de imágenes espectrales. (a) Sensor Whiskbroom, (b) Sensor Pushbroom, y (c) Filtrado espectral[Autor].

Los principales pasos de la calibración radiométrica incluyen:

- *Corrección de oscuridad:* Se elimina la señal residual que pueda estar presente cuando no hay luz en el sistema. Esto es importante para corregir cualquier ruido generado por el sensor o los componentes electrónicos.
- *Corrección de no linealidades:* En algunos sistemas, la respuesta del detector no es lineal en todas las intensidades de luz. La corrección de no linealidades permite ajustar los datos para que correspondan a una respuesta lineal ideal.
- *Corrección de reflectancia:* La reflectancia espectral medida por el sistema puede estar influenciada por la iluminación no homogénea o la variabilidad en las propiedades reflectivas del objeto. El sistema se calibra utilizando paneles de referencia de reflectancia

conocida, lo que permite ajustar los datos de reflectancia en cada longitud de onda y eliminar los efectos de la iluminación no uniforme [43].

Fórmula para la calibración de reflectancia:

$$R(\lambda) = \frac{I(\lambda)_{\text{objeto}} - I(\lambda)_{\text{oscuridad}}}{I(\lambda)_{\text{referencia}} - I(\lambda)_{\text{oscuridad}}} \quad (4.9)$$

Donde:

$R(\lambda)$ es la reflectancia calibrada.

$I(\lambda)_{\text{objeto}}$ es la intensidad medida en el objeto.

$I(\lambda)_{\text{oscuridad}}$ es la señal de oscuridad.

$I(\lambda)_{\text{referencia}}$ es la intensidad medida en el panel de referencia de reflectancia conocida.

Este proceso asegura que las imágenes hiperespectrales capturadas reflejen con precisión las propiedades ópticas del objeto sin que factores externos, como la iluminación o el ruido del sistema, interfieran con los datos.

Calibración espectral: La calibración espectral es el ajuste de las longitudes de onda que el sistema hiperespectral captura para que correspondan a los valores correctos de longitud de onda esperados. Es fundamental que las longitudes de onda capturadas sean exactas, ya que cualquier desviación puede llevar a errores en la clasificación y análisis espectral.

Para realizar la calibración espectral, se utiliza una fuente de luz conocida, como una lámpara de referencia con líneas espectrales de emisión conocidas (como una lámpara de mercurio). El sistema ajusta sus mediciones para que cada longitud de onda capturada coincida exactamente con las longitudes de onda de referencia, asegurando que los datos espectrales sean precisos (ver figura 4.14) [45].




Figura 4.14 Calibración espectral para un sistema de imágenes hiperespectrales de escaneo lineal utilizando lámparas de calibración de xenón y mercurio-argón[36].

Alineación espacial: La alineación espacial es el proceso que asegura que las imágenes capturadas a diferentes longitudes de onda estén correctamente registradas en el mismo plano espacial. Debido a que el sistema hiperespectral captura una imagen en cada longitud de onda, es esencial que los píxeles de cada imagen coincidan exactamente en la misma posición espacial (ver figura 4.15). Cualquier desplazamiento o distorsión entre las imágenes espectrales puede generar errores en el análisis.

La alineación espacial es particularmente importante en aplicaciones industriales donde los objetos pueden moverse durante la adquisición de imágenes. En una línea de producción de frutos cítricos, por ejemplo, la falta de alineación adecuada entre las imágenes puede generar errores de clasificación y afectar la precisión del análisis de calidad [43].




Figura 4.15 Calibración espacial para un sistema de imágenes hiperespectrales de escaneo lineal utilizando un papel blanco impreso con líneas paralelas delgadas separadas por 2 mm[36].

En la evaluación de frutos cítricos mediante imágenes hiperespectrales, el proceso de calibración asegura que las imágenes capturadas en diferentes longitudes de onda proporcionen información precisa sobre la composición del fruto. La calibración radiométrica garantiza que las imágenes reflejen las propiedades ópticas reales del fruto, mientras que la calibración espectral asegura que las longitudes de onda medidas sean correctas. Por otro lado, la alineación espacial es esencial para que los defectos y características internas o externas sean detectados correctamente en cada longitud de onda.

Este proceso es crucial en la clasificación de calidad en la industria agrícola, ya que errores en la calibración o alineación pueden llevar a la clasificación errónea de los frutos, afectando la calidad del producto final.

4.5 Algoritmos de Procesamiento y Análisis de Imágenes Hiperespectrales

4.5.1 Redes neuronales.

Las redes neuronales artificiales (RNA), inspiradas en el funcionamiento del cerebro humano, han experimentado un impresionante desarrollo a lo largo del tiempo. La primera red neuronal conocida se denomina "Perceptrón" y fue desarrollada por los científicos Frank Rosenblatt y Bernard Widrow en la década de 1950. El Perceptrón es una red neuronal de una sola capa (monocapa) que puede ser entrenada para clasificar patrones. Sin embargo, sus capacidades estaban limitadas a problemas linealmente separables. A medida que la investigación en redes neuronales avanzaba, surgieron nuevas arquitecturas y técnicas que permitieron el procesamiento de información más compleja. En la década de 1980, los científicos propusieron las redes neuronales de retropropagación, que permitían el entrenamiento de redes con varias capas (multicapa) y superaban las limitaciones del Perceptrón original. A partir de entonces, el campo de las redes neuronales experimentó un rápido crecimiento y se desarrollaron numerosas arquitecturas y algoritmos. Surgieron modelos como las redes neuronales convolucionales (CNN) para el procesamiento de imágenes, las redes neuronales recurrentes (RNN) para el procesamiento de secuencias y las redes neuronales generativas (GAN) para la generación de contenido[46].

Los algoritmos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), son particularmente efectivos al aprender características espaciales y espectrales directamente de los datos, lo que los hace ideales para aplicaciones en las que los patrones espectrales no son fácilmente discernibles. Este enfoque es útil en la clasificación de productos agrícolas, como los frutos cítricos, ya que puede identificar defectos sutiles en las firmas espectrales de los frutos [47].

Ventajas de las redes neuronales en la clasificación hiperespectral:

1. *Aprendizaje no lineal:* Las redes neuronales pueden aprender relaciones complejas y no lineales entre los datos de entrada (longitudes de onda espectrales) y las etiquetas de salida (clases de objetos o materiales), lo que las hace muy útiles en escenarios como la clasificación de defectos en productos agrícolas [46].
2. *Tolerancia al ruido:* Los algoritmos de redes neuronales tienen una mayor tolerancia al ruido en comparación con los métodos tradicionales, lo que los hace más robustos en

condiciones de adquisición de imágenes subóptimas, como variaciones en la iluminación [47].

3. *Reducción de dimensionalidad*: Algunas arquitecturas, como las redes neuronales convolucionales, permiten la reducción automática de las características irrelevantes, mejorando la eficiencia en la clasificación sin perder precisión [46].

Funcionamiento de una Neurona Artificial

Una neurona artificial simula el funcionamiento de una neurona biológica a través de un modelo matemático. Cada neurona recibe una serie de entradas $(x_1, x_2, \dots, x_n)$, las pondera con un peso $(w_1, w_2, \dots, w_n)$ y aplica una función de activación (f) que transforma la combinación lineal de las entradas en una salida. Este proceso se representa con la ecuación:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (4.10)$$

Donde:

y es la salida de la neurona.

w_i representa los pesos asociados a cada entrada x_i .

b es el sesgo de la neurona.

f es una función de activación, como la función sigmoide o ReLU, que introduce no linealidad [38].




Figura 4.16 Estructura simple de una neuronal artificial[Autor].

Estructura de las Redes Neuronales

Las redes neuronales están estructuradas en capas: una capa de entrada, una o más capas ocultas y una capa de salida.




Figura 4.17 Esquema red neuronal [Autor].

La figura 4.17 muestra un ejemplo de red neuronal multicapa, donde cada capa oculta se encarga de procesar y transformar los datos recibidos de la capa anterior, permitiendo que la red aprenda relaciones no lineales complejas. Este diseño modular permite a la red adaptar los pesos durante el proceso de entrenamiento para minimizar el error de predicción[46].

4.5.2 Red Neuronal Tipo BackPropagation

El algoritmo de retropropagación (backpropagation) es fundamental en el entrenamiento de redes neuronales multicapa, donde ajusta los pesos sinápticos para minimizar el error entre la salida deseada y la generada por la red. En el contexto de procesamiento de imágenes hiperespectrales, se utiliza para aprender características complejas en los datos de entrada, como patrones espectrales que permiten clasificar objetos o detectar defectos en productos alimentarios.

Proceso de Retropropagación

La retropropagación se realiza en dos fases: la fase hacia adelante y la fase hacia atrás. En la fase hacia adelante, las entradas de la red se multiplican por los pesos y se procesan a través de una función de activación en cada neurona de las capas ocultas y la capa de salida:

$$y_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_j\right) \quad (4.11)$$

Donde:

y_j es la salida de la neurona j .

x_i representa las entradas.

w_{ij} es el peso de la conexión entre la entrada i y la neurona j .

b_j es el sesgo de la neurona.

f es una función de activación, como la función sigmoide o ReLU, que introduce no linealidad [38].

En la fase hacia atrás, el error se propaga desde la capa de salida hacia las capas ocultas, ajustando los pesos mediante el gradiente descendente. Para cada peso, el ajuste se calcula como:

$$E = \frac{1}{2} \sum_{k=1}^n (y_k - \widehat{y}_k)^2 \quad (4.12)$$

Donde:

y_k es el valor real.

$\widehat{y}_k$ es el valor predicho por la red para la salida k .

En aplicaciones hiperespectrales, es común que las redes neuronales se combinen con métodos de reducción de dimensionalidad para mejorar la eficiencia y precisión. Un enfoque popular es usar Análisis de Componentes Principales (PCA) o Análisis de Componentes Independientes (ICA) antes de entrenar la red neuronal, con el objetivo de reducir el número de bandas espectrales relevantes y eliminar la redundancia de los datos [48].

4.5.3 Técnicas de reducción de dimensionalidad y selección de características relevantes

Debido a la gran cantidad de datos generados por los sistemas hiperespectrales, la reducción de dimensionalidad y la selección de características son esenciales para mejorar la eficiencia computacional y la precisión de los algoritmos de clasificación. Estas técnicas permiten reducir el número de bandas espectrales y, al mismo tiempo, mantener la información más relevante para la tarea de clasificación[46].

Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales (PCA) es una técnica matemática que reduce la dimensionalidad de grandes conjuntos de datos sin perder información clave. En imágenes hiperespectrales, esto es particularmente útil para simplificar los datos, ya que cada píxel de la imagen contiene una gran cantidad de información espectral. La fórmula básica de PCA está dada matemáticamente en la Ecuación 4.5.

Fundamento Matemático del PCA

El PCA se basa en la transformación lineal de los datos a un nuevo sistema de coordenadas en el que las variables originales (bandas espectrales) son reemplazadas por componentes principales, que son combinaciones lineales de las variables originales. Estas componentes capturan la mayor parte de la variabilidad presente en los datos. Matemáticamente, el PCA busca maximizar la varianza proyectada en las nuevas dimensiones. El procedimiento básico de PCA sigue estos pasos:

- **Cálculo de la matriz de covarianza** de los datos:

$$C = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \quad (4.13)$$

Donde:

C es la matriz de covarianza.

X_i es el vector de datos de entrada.

$\bar{X}$ es el promedio de los datos.

T es la transpuesta de la matriz generada por $(X_i - \bar{X})$

- *Descomposición en valores y vectores propios:* Se calculan los autovalores (λ_i) y los autovectores (w_i) de la matriz de covarianza. Los autovectores definen las nuevas direcciones (componentes principales), mientras que los autovalores indican la cantidad de varianza capturada por cada componente.
- *Proyección de los datos originales* en el nuevo espacio definido por los autovectores:

$$Z = W^T \cdot X \quad (4.14)$$

Donde:

Z es el conjunto de datos transformados (componentes principales).

W es la matriz de pesos (autovectores de la matriz de covarianza).

X es el conjunto de datos originales (el datacubo en este caso).

Esta proyección permite reducir la dimensionalidad de los datos, eliminando componentes que capturan menos varianza y manteniendo solo las más significativas.

Aplicación en Imágenes Hiperespectrales

En el caso de imágenes hiperespectrales, el PCA se utiliza para reducir el número de bandas espectrales mientras se mantiene la información más relevante para la tarea de análisis. Esto facilita el procesamiento de los datos y permite clasificar más rápidamente los objetos en las imágenes.

Proceso de PCA:

1. *Extracción del Datacubo:* Cada imagen hiperespectral se puede representar como un cubo tridimensional con dos dimensiones espaciales y una dimensión espectral (longitud de onda).
2. *Transformación con PCA:* Se aplica el análisis de componentes principales al datacubo, proyectando los datos en el espacio de componentes principales. Las primeras componentes principales (PC1, PC2, PC3) son aquellas que capturan la mayor parte de la varianza en los datos.
3. *Generación de Imágenes de Puntuaciones:* Las componentes principales obtenidas pueden visualizarse como *imágenes de puntuaciones*, donde cada imagen representa la variación en los datos capturada por una componente. Esto permite detectar patrones espectrales y espaciales no visibles en las imágenes originales.




Figura 4.18 PCA aplicándose a los datos hiperespectrales para generar imágenes de puntuaciones[Autor].

En la figura 4.18 se puede visualizar cómo las componentes principales pueden simplificar la complejidad de los datos hiperespectrales y revelar características importantes para su análisis.

Ventajas del PCA en Imágenes Hiperespectrales

1. *Reducción de Dimensionalidad:* El PCA permite reducir significativamente el número de bandas a analizar, disminuyendo así los requerimientos de almacenamiento y procesamiento.
2. *Eliminación de Redundancia:* Dado que muchas bandas espectrales contienen información redundante, el PCA ayuda a eliminar dicha redundancia, manteniendo solo las variaciones relevantes para la clasificación o detección de defectos en los objetos analizados.
3. *Clasificación Mejorada:* Al reducir la complejidad de los datos, el PCA facilita la tarea de los algoritmos de clasificación, mejorando tanto la velocidad como la precisión del análisis[46].

El uso de PCA en imágenes hiperespectrales ofrece una forma eficiente de procesar y analizar grandes volúmenes de datos espectrales. Al reducir la dimensionalidad, los investigadores pueden concentrarse en las bandas que contienen la mayor cantidad de información relevante, facilitando así la clasificación y el análisis de productos agrícolas, como los frutos cítricos.

4.6 Estudios y Casos de Éxito en la Clasificación de Frutos Cítricos

El uso de imágenes hiperespectrales para la clasificación y detección de defectos en frutos cítricos ha sido ampliamente investigado, con resultados positivos que han contribuido al desarrollo de sistemas de clasificación más eficientes y precisos en la industria alimentaria. Los estudios se han centrado en aspectos como la detección de enfermedades, defectos superficiales y la calidad interna del fruto.

Uno de los estudios más destacados realizado en la Ref. [38], quienes aplicaron imágenes de reflectancia hiperespectral para la detección del canker de los cítricos, una enfermedad bacteriana causada por *Xanthomonas axonopodis* pv. *citri* que afecta la cáscara, hojas y tallos de frutas cítricas, y que es altamente contagiosa y destructiva en los cultivos de cítricos. Este estudio utilizó un rango espectral de 450 nm a 930 nm, desarrollando un algoritmo capaz de clasificar con éxito las lesiones por canker en la cáscara del fruto con una precisión del 92%. Los resultados mostraron que las lesiones eran más distinguibles en la región espectral de 600 a 700 nm, lo cual permitió una detección temprana de la enfermedad en toronjas infectadas, antes de que las lesiones fueran visibles al ojo humano. Esta investigación subraya la importancia de la detección temprana mediante tecnología hiperespectral en la agricultura de precisión, promoviendo estrategias de manejo más efectivas y localizadas para la protección de los cultivos cítricos [38].

Otro trabajo relevante fue realizado en la Ref. [28], quienes desarrollaron un sistema multispectral para identificar defectos comunes en la piel de los cítricos. Utilizaron imágenes de variedades comerciales como la mandarina Clemenules y la naranja Valencia, combinando cámaras de infrarrojo cercano (NIR), ultravioleta (UV) y color bajo iluminación blanca. Este estudio permitió clasificar defectos severos como la antracnosis y la podredumbre verde con altos niveles de precisión. Los resultados demostraron que los sistemas de visión por computadora pueden mejorar significativamente los métodos manuales tradicionales utilizados en las plantas empacadoras [28].

En la detección temprana de frutas podridas, Ref. [49] utilizaron imágenes hiperespectrales para analizar mandarinas infectadas artificialmente con *Penicillium digitatum*. A través del análisis espectral, lograron identificar las primeras etapas de la infección antes de que fuera visible para el

ojo humano, lo que demuestra el potencial de las imágenes hiperespectrales para prevenir la propagación de enfermedades en lotes de frutas almacenadas [49].

Estos estudios confirman que la tecnología hiperespectral ofrece una ventaja significativa en la clasificación automática de cítricos, permitiendo la identificación de enfermedades y defectos que no son detectables mediante métodos convencionales, lo que reduce las pérdidas económicas y mejora la eficiencia en el control de calidad.

4.6.1 Comparación con Estudios Previos

Diversos estudios han explorado la aplicación de la espectroscopía VNIR en la evaluación de la calidad de frutos cítricos. Por ejemplo, el trabajo de Díaz Hurtado Ref. [50] revisó estudios recientes sobre la espectroscopía de infrarrojo cercano (NIRS) aplicada a la calidad de frutos cítricos. Los resultados destacaron que las técnicas basadas en reflectancia proporcionan alta precisión en parámetros como sólidos solubles, acidez titulable y madurez del fruto, siempre que se validen mediante modelos multivariantes.

Por otro lado, Lorente Ref. [51] evaluaron el potencial de la espectroscopía VNIR para detectar automáticamente lesiones de podredumbre en cítricos. Utilizando métodos de aprendizaje automático, lograron una precisión de clasificación del 97.8 %, demostrando la eficacia de estas técnicas en la detección de enfermedades poscosecha.

Estos estudios respaldan la eficacia de la espectroscopía VNIR combinada con análisis multivariado y aprendizaje automático, alineándose con el enfoque propuesto en este trabajo.

5. Descripción del montaje experimental y registro de datos

5.1 Descripción General del Sistema

El registro de datos o imágenes hiperespectrales se llevó a cabo utilizando una cámara hiperespectral Specim FX10e, un dispositivo diseñado para capturar imágenes en el rango visible e infrarrojo cercano (VNIR) de 400 a 1000 nm. Este modelo, con número de serie 3210670, emplea una configuración de escaneo lineal (*pushbroom*), capturando una línea de la escena por vez y con la ayuda de una banda transportadora se genera un cubo de datos hiperespectral que permiten un análisis espectral detallado de cada pixel de la muestra, ver figura 5.1.




Figura 5.1 Conceptualización general del sistema[Autor].

Sistema Óptico

El sistema óptico utilizado en este trabajo se basa en la cámara hiperespectral Specim FX10e, diseñada específicamente para aplicaciones en el rango visible e infrarrojo cercano (VNIR). Este equipo es reconocido por su capacidad de capturar imágenes hiperespectrales con alta resolución y precisión, convirtiéndolo en una herramienta ideal para la clasificación de productos agrícolas como frutos cítricos.

El sistema óptico presenta características técnicas clave, como una resolución espectral de 1.34 nm, lo que permite detectar variaciones sutiles en las firmas espectrales de los frutos. Además, su rango espectral abarca desde 400 nm hasta 1000 nm, cubriendo tanto la región visible como el infrarrojo cercano, lo que permite analizar características relacionadas con el color, contenido de

agua y composición química de los frutos. Todo esto es posible gracias a un sensor CMOS de alta sensibilidad, capaz de detectar diferencias mínimas en la reflectancia espectral.

Componentes del Montaje.

El sistema de registro de las imágenes hiperespectrales está constituido por los siguientes componentes:

- *Cámara Specim FX10e*: La cámara se montó sobre la banda transportadora utilizando un soporte de trípode estándar. Este dispositivo proporciona una excelente precisión en la captura de datos debido a su alta velocidad de fotogramas, alcanzando hasta 330 fps (frame per seconds) en el modo de imagen completa, ver figura 5.1, 5.2 y 5.3.



Figura 5.2 Cámara Specim FX10e

- *Banda Transportadora*: Se utilizó para mover las muestras de las mandarinas bajo la cámara, operando con dos velocidades específicas: 40 mm/s durante el posicionamiento para ajustar la ubicación inicial de las muestras y 10 mm/s durante el escaneo para garantizar una captura precisa y uniforme de cada línea de la imagen. Este método asegura una adquisición continua de datos y es ideal para el escaneo en línea de productos en movimiento, garantizando que las imágenes espectrales estén correctamente alineadas para formar un datacubo hiperespectral de alta calidad.

- *PC de Adquisición de Datos:* La cámara está conectada a un ordenador mediante una interfaz GigE, lo que facilita la transmisión de datos de alta velocidad. El *software Lumo ToolKit* se utilizó para controlar la cámara, la banda transportadora, realizar la calibración espectral y almacenar las imágenes registradas (obtención de datos).
- *Iluminación Controlada:* Se instaló iluminación LED uniforme en ambos lados de la banda transportadora para lograr una iluminación homogénea logrando minimizar sombras y reflejos y mantener una luz constante necesaria para la calibración y la captura precisa de datos espectrales, ver figura 5.3.




Figura 5.3 Esquema de sistema pushbroom incorporado en una banda transportadora[Autor].

5.2 Procedimiento Experimental

Para obtener el registro de las imágenes hiperespectrales es necesario realizar una calibración de sistema de adquisición, establecer las condiciones de iluminación adecuadas y acondicionar las muestras de la forma más adecuadas y ajustadas de la manera más cercana a una situación real de adquisición en campo.


- *Calibración de la Cámara:* Antes de comenzar la adquisición de datos, la cámara se calibró utilizando referencias de blanco y negro. Este proceso es fundamental para asegurar la precisión en la captación de la respuesta espectral de las muestras, eliminando las

variaciones causadas por factores externos, como la intensidad de la iluminación y las características del sensor. La calibración ayuda a normalizar la respuesta del sistema, garantizando que la reflectancia registrada sea una representación precisa de las propiedades espectrales de la muestra.

Para la calibración:

- Se utilizaron varias capturas de una superficie blanca difusa, obteniendo la reflectancia promedio de esta superficie para representar nuestra firma espectral del blanco (ver figura 5.4 (a)). Esta firma se utiliza como punto de referencia para indicar el nivel máximo de reflectancia, equivalente a un 100% de reflectancia ideal.
- De manera similar, se empleó una superficie negra difusa para registrar la mínima reflectancia esperada (aproximadamente cero) y se calculó su valor medio, representando así la firma espectral del negro (ver figura 5.4 (b)).

La normalización espectral, como se describe en la Ecuación 4.6, permitió ajustar los valores de reflectancia eliminando efectos de iluminación y ruido. Este proceso aseguró que los datos analizados reflejaran únicamente las propiedades intrínsecas de las muestras.






Figura 5.4 a) Firma espectral del blanco; b) Firma espectral del negro[Autor].

Este proceso de calibración y normalización permite obtener un valor de reflectancia que varía de 0 a 1 (o de 0 a 100%), donde 0 representa la mínima reflectancia (negro) y 1 la máxima reflectancia (blanco) (ver figura 5.5). De esta forma, las imágenes hiperespectrales calibradas reflejan únicamente las características espectrales intrínsecas de la muestra, eliminando las influencias de iluminación y sensibilidad del sensor, lo cual es crucial para un análisis preciso y consistente de los datos espectrales. La comparación se ve reflejada en la figura 5.7, donde se presentan dos imágenes: una no normalizada (figura 5.7 (a)) y otra normalizada (figura 5.7 (b)).




Figura 5.5 a) Firma espectral no normalizado (pixel mandarina) ; b) Firma espectral normalizado (pixel mandarina) [Autor].

Preparación de Muestras: Las mandarinas en este caso se colocaron sobre la banda transportadora, asegurando que cada muestra pasara directamente bajo la cámara. Se tomaron muestras con diferentes niveles de maduración para obtener una base de datos variada.




Figura 5.6 Montaje Experimental para Adquisición de Imágenes Hiperespectrales con la Cámara Specim FX10e. Preparación de la muestra en la banda transportadora[Autor].

Conforme la banda se desplazaba, la cámara espectral Specim FX10e adquiría imágenes hiperespectrales en tiempo real. Las imágenes obtenidas se almacenaron como cubos de datos, cada uno compuesto por bandas espectrales que representan la respuesta de cada píxel en el rango de 400 a 1000 nm. Cada imagen registrada tiene una dimensión de 1050x1024 píxeles (ver figura 5.7), y por cada píxel se registraron 448 longitudes de onda, con una resolución espectral de $\Delta\lambda = 1.34$ nm, resultando en un datacubo espectral de 1050 [píxeles] x 1024 [píxeles] x 448 [λ]. En total, se obtuvieron 6 datacubos espectrales representativos. Las muestras están constituidas por 35 mandarinas reales (17 verdes, 11 pintonas y 7 maduras), sobre las cuales se crearon 105 datos adicionales con ruido para aumentar la robustez del conjunto, alcanzando un total de 140 muestras. Este conjunto fue utilizado para construir el sistema de clasificación automática de mandarinas de acuerdo a su estado de maduración (ver figura 5.6).




Figura 5.7 Imagen capturada por la cámara Specim FX10e; a) Imagen no Normalizada; b) Imagen Normalizada[Autor].

El software Lumo ToolKit, tiene la posibilidad de permitir obtener información de acuerdo a la necesidad, se puede obtener de los datacubos espectrales, imágenes (*slices*) en cada una de las longitudes registradas por el sistema y así mismo, el espectro registrado por cada pixel de la imagen. Las imágenes se guardaron en el formato hiperespectral adecuado, cuya cantidad de índices o longitudes de onda de la matriz de volumen es de 448 para su posterior análisis mediante algoritmos de aprendizaje profundo, enfocados en clasificar y evaluar el estado de maduración de los cítricos. En la figura 5.7 se puede observar algunas imágenes en los índices (1, 21, 41, 61, 81, 101, 121, 141, 161, 181, 201, 221, 241, 261, 281, 301, 321, 341, 361, 381, 401, 421, 441) o longitudes correspondientes (400 nm, 426.8 nm, 453.7 nm, 480.5 nm, 507.4 nm, 534.2 nm, 561 nm, 587.9 nm, 614.8 nm, 641.6 nm, 668.4 nm, 695.3 nm, 722.1 nm, 749 nm, 775.8 nm, 802.7 nm, 829.5 nm, 856.3 nm, 883.2 nm, 910 nm, 937 nm, 963.8 nm, 990.6 nm). Se puede observar que las imágenes correspondientes a las longitudes de onda (400 nm a 507.4 nm), no brindan información relevante, que pueda ser de valor para la discriminación de estados de maduración. Sin embargo, las demás longitudes de onda (534.2 nm a 990.6 nm), si se tiene información de importancia que puede permitir discriminar el estado de maduración de las mandarinas.




Figura 5.8 Índices de la matriz del DataCubo[Autor].

Unas de las ventajas de la utilización de la cámara hiperespectral Specim FX10e es la capacidad de seleccionar bandas específicas que permiten enfocar el análisis en rangos espectrales de interés, facilitando la detección de características espectrales precisas relacionadas con la madurez y calidad de los cítricos y una velocidad de adquisición de hasta 330 fps en su modo completo, esta cámara es ideal para la inspección rápida en líneas de procesamiento de alimentos, donde se requiere alta velocidad sin comprometer la precisión.

El uso de una interfaz GigE estándar y el soporte de software de análisis como el Lumo ToolKit hacen que el sistema sea fácil de implementar e integrar en procesos de control de calidad automatizados. Este montaje experimental con la Specim FX10e nos proporciona una solución robusta y precisa para la captura de imágenes hiperespectrales en tiempo real, permitiendo el análisis no destructivo de productos agrícolas y facilitando la implementación de sistemas de inspección automatizada en entornos industriales.

Sin embargo, en este trabajo solo se utilizó el software para el registro de los datacubos espectrales y para la visualización de las imágenes y los espectros cuando fuese necesario.

6. Resultados y Análisis

Los resultados de este trabajo están soportados en la implementación de las siguientes etapas metodológicas: la adquisición de los datacubos hiperespectrales de mandarinas de la región del departamento de Santander, utilizando una cámara hiperespectral VNIR, posteriormente, una serie de pasos enmarcados dentro del procesamiento digital de imágenes, con el propósito de segmentar la región en la imagen que ocupan cada mandarina, seguidamente, la extracción de los espectros o firmas espectrales del objeto de interés, seguido de una etapa de reducción de dimensionalidad, así como, la selección de características y por último, la etapa de clasificación de los estados de maduración de las mandarinas utilizando algoritmos de aprendizaje profundo, es decir, redes neuronales profundas (NN) (ver figura 6.1). A continuación, se detallan los principales resultados obtenidos en cada una de las fases del procesamiento de los datos.




Figura 6.1 Etapa de la metodología aplicada[Autor].

Adquisición de datacubos hiperespectrales

Los datacubos hiperespectrales generados mediante la cámara Specim FX10e fueron procesados para extraer características espectrales relevantes, como se describe en la Descripción del Montaje

Experimental. Estos datacubos proporcionaron la base para la clasificación de los frutos en diferentes categorías de calidad.

Segmentación de imágenes hiperespectrales

Tras la captura de imágenes espectrales en diferentes bandas del espectro visible e infrarrojo cercano, se llevaron a cabo varias etapas de procesamiento que incluyen la segmentación de las mandarinas del fondo. Esto permite aislar las regiones de interés en cada imagen y reducir el ruido introducido por otros objetos en la escena.

Se seleccionaron bandas específicas (562.4 nm, 750 nm y 951.7 nm), bandas en las que es posible identificar y diferenciar de forma más efectiva los bordes de los objetos en la imagen. A partir de estas tres bandas, se generó una nueva imagen, con el contenido espectral de interés, tal como se muestra en la Figura 6.2.




Figura 6.2 Segmentación de Cítricos[Autor].

Se realizó un proceso de procesamiento de imágenes paso a paso, que permite segmentar los objetos de interés: se construyó una imagen de tres planos con las bandas seleccionadas, la cual se puede

visualizar como una imagen a color (ver figura 6.2 (a)). Posteriormente, a través de una transformación se convierte a una imagen de niveles de gris (ver figura 6.2 (b)). Seguidamente se realiza una umbralización, lo que permite obtener una imagen binaria (ver figura 6.2 (c)). Después, se realiza un proceso de eliminación de pequeños elementos aislados de áreas pequeñas, junto con un proceso de remoción de filamentos y de desconexión de objetos por medio de una erosión-dilatación (ver figura 6.2 (d-e)). Se sigue con una operación de relleno de objeto (*filled*), con el propósito de establecer objetos compactos, muy particularmente los de interés (ver figura 6.2 (f)). En seguida, se calcula los bordes de los objetos aislados y se calcula el nivel de circularidad de cada objeto y selección los que tengan un mayor grado de circularidad (ver figura 6.2 (g)). Esto finalmente nos permite obtener los objetos deseados, lo que constituye una máscara binaria (ver figura 6.2 (h)). Finalmente, se le asigna una etiqueta a cada objeto binario presente en la imagen, permitiendo aislar cada uno de ellos (ver figura 6.2 (i), 6.3).

Tabla 6.1: Pasos realizados para la segmentación independiente de cada objeto en la imagen.

Paso	Descripción
1. Imagen	Imagen creada en color (562.4 nm, 750 nm y 951.7 nm) que muestra los objetos de interés.
2. Niveles de Gris	Conversión de la imagen a escala de grises para simplificar la información visual.
3. Umbralización	Aplicación de un umbral para convertir la imagen a formato binario (blanco y negro), separando objetos del fondo.
4. Remoción de Ruido	Eliminación de componentes pequeños o ruido no deseado para limpiar la imagen.
5. Erosión y Dilatación	Aplicación de operaciones morfológicas para suavizar bordes y eliminar imperfecciones en los objetos.
6. Relleno	Relleno de áreas internas en los objetos para hacerlos sólidos y sin huecos.
7. Detección de Bordes	Resaltado de los contornos de los objetos para una mejor definición de sus límites.
8. Segmentación	Separación de los objetos de interés del fondo, dejando un fondo uniforme o negro.
9. Etiquetado	Asignación de etiquetas o tonos individuales a cada objeto para su identificación y análisis individual.

Como se puede observar en la figura 6.3, se lograron segmentar las mandarinas de manera exitosa, produciendo imágenes donde los objetos estaban correctamente delimitados para todos los casos. La segmentación mostró resultados efectivos en aislamiento de los cítricos en cada imagen.




Figura 6.3 Objetos Aislados

Extracción de los espectros o firmas espectrales del objeto.

Una vez que se tiene la posibilidad de aislar las mandarinas de forma individual, se procede a extraer la información contenida en cada píxel. Esta información, corresponde al contenido de longitudes ondas sensadas por la cámara hiperespectral, es decir, se obtiene las firmas espectrales correspondientes a cada objeto aislado. Esta información espectral, de cada objeto aislado (mandarina), es etiquetada en cada caso, el cual permite diferenciar la información extraída de cada objeto de interés (mandarina). Las firmas extraídas para las mandarinas ejemplo presente en las imágenes anterior, se muestran en la figura 6.4.




Figura 6.4 Múltiples firmas espectrales de cada mandarina[Autor].

Reducción de dimensionalidad y extracción de características

Para analizar las firmas espectrales obtenidas de los objetos aislados, se utilizó el Análisis de Componentes Principales (PCA), una técnica estadística que permite reducir la dimensionalidad de los datos sin perder la mayor parte de la variabilidad presente. Este proceso facilita la identificación de patrones y la discriminación de objetos en función de sus características espectrales.

Aplicación de PCA en las Firmas Espectrales

Se implementó el procedimiento que permite obtener las componentes principales de las firmas espectrales. Las firmas espectrales contienen 448 datos o bandas de frecuencias. Al aplicar el PCA se reduce el número de datos a 15 (componentes principales). Posteriormente se seleccionan componentes principales que contienen mayor información y se eligió las que contienen el 97%. Esto nos permitió seleccionar las seis (6) primeras componentes

principales por ser las que contienen la mayor cantidad de información relevante para la clasificación de las muestras.




Figura 6.5 (a) Extracción de componentes principales de las firmas espectrales; (b) Selección de las componentes principales con mayor información[Autor].

A través de la representación gráfica de las muestras en el espacio de los componentes principales, permite obtener una separación entre los distintos grupos de calidad de los cítricos y sobre todo la reducción de la dimensionalidad en situaciones donde el número de características que se tiene es demasiado alto, en nuestro caso es de 448. Esta respalda la eficacia del PCA para reducir la complejidad de los datos espectrales y mejorar la discriminación entre clases de objetos. Además, los resultados del PCA constituyeron la base para el desarrollo de algoritmos de clasificación más precisos y eficientes, optimizando el rendimiento de la arquitectura de red neuronal en las etapas de entrenamiento y validación.

La implementación del PCA no solo facilita el procesamiento de los datos, sino que también que contribuye a una mejor visualización y comprensión de las relaciones entre las distintas firmas espectrales, permitiendo una clasificación más robusta y precisa de los cítricos. Este procedimiento fue aplicado a cada una de las mandarinas.

Implementación de la red Neuronal

El entrenamiento de la red neuronal se realizó haciendo uso del Toolbox de Neural Network de MATLAB. La red neuronal que se implementó es una red neuronal multicapa, la cual es una red que constan de una capa de entrada, por la cual se ingresan las características seleccionadas, es

decir, las componentes PCA reducidas, un bloque de capas ocultas, que el número de capas oculta se determinará de acuerdo a la efectividad de la red y una capa de salida que será la encargada de indicar en qué grado de maduración en que se encontrará la mandarina. Para escoger la arquitectura de la red neuronal, se realizó un proceso de búsqueda sistemática en función del rendimiento o precisión de la red, al momento de clasificar los estados de maduración. El nivel de maduración de las mandarinas se estableció en tres clases, las cuales son: verde, pintón y maduro. El proceso de etiquetar el estado de maduración de las mandarinas se realizó con ayuda de personas que habitualmente recolectan y clasifican las mandarinas por su estado de maduración, obteniendo así una clasificación subjetiva, pero, soportada en la experticia de estas personas dedicadas y con experiencia en clasificar mandarinas. El algoritmo de entrenamiento de la red neuronal multicapa utilizado es conocido como *backpropagation*. El cual consiste en, después de presentar las entradas a la red y obtener las salidas, se evalúa el error y de acuerdo al tamaño del error este modifican los pesos o sinapsis desde la última capa (capa de salida) hacia las capas anteriores (capas ocultas), hasta llegar a la primera capa (capa de entrada). Este proceso se repite hasta lograr un mínimo aceptable. Esta es la razón por la cual se le conoce como *backpropagation*, porque la modificación de los pesos se realiza de atrás hacia adelante en función del tamaño del error cometido por la red. Existen algoritmos que aceleran este proceso, los cuales son algoritmos conocidos dentro del área de la optimización. Es así, que los algoritmos de búsqueda de la minimización del error existen en varias versiones del algoritmo clásico de gradiente descendente. En este caso, se utilizó el algoritmo Levenberg-Marquardt *backpropagation*, que es mucho más rápido que los otros existentes.

Inicialmente, se preparan los datos de entrada construyendo una matriz de 6x35, cuya dimensión está determinada por el número de componentes principales seleccionadas (6) y el número total de espectros de todas las mandarinas (35). Los espectros de cada mandarina están etiquetados, y la cantidad de espectros por mandarina es diferente, ya que depende del número de píxeles presentes en cada una. Los datos de salida se organizaron en una matriz de 3x35, en donde las tres filas están compuestas por 0s y 1s. Un 1 indica que se activa una clase (verde, pintón o maduro), dependiendo de la fila en donde se coloque. En cada columna, solo puede haber una clase activada. Se prestó especial atención para garantizar que haya una correspondencia precisa entre las componentes principales de cada mandarina y la clase asignada. También, con el propósito de crear mayor

número de ejemplos de entrenamiento y hacer que la red neuronal entrenada sea más robusta frente a pequeñas variaciones de las entradas o en las componentes principales, se creó una matriz adicional con datos con un ruido aleatorio blanco, al cual también se le asignaron las clases correspondientes. Esta estrategia permite tener el doble de ejemplos de entrenamiento.

Posteriormente se divide los datos armados anteriormente en tres subconjuntos: una de entrenamiento correspondiente al 70% de los datos originales, uno de validación, con un 15%, los cuales son datos que no participan en el entrenamiento, pero que al momento del entrenamiento se tienen de referencia y por último otro subconjunto de testeo con el 15%, el cual, no participa en el entrenamiento y sirven para evaluar la red con datos que no fueron tenidos en cuenta para nada en el entrenamiento. Durante el entrenamiento, la red ajusta sus pesos en función de los errores entre las predicciones y las etiquetas de correctas y se hace necesario técnicas de regularización, como el *dropout*, para evitar el sobreajuste del modelo.

Es claro que la red neuronal tendrá 6 neuronas en la capa de entrada, establecidos por las componentes principales reducidas y 3 neuronas en la capa de salida, determinadas por el número de clases establecido. Ahora, hace falta encontrar cuantas capas ocultas y cuantas neuronas por capa oculta tendrá la red neuronal que sea capaz de realizar la clasificación con mayor precisión. Para esto se hizo una búsqueda sistemática en la cual se definieron dos capas ocultas y en cada capa oculta de hizo un barrido de número de neuronas. Para ello, se entrenaron 81 redes neuronales con dos capas ocultas y diferentes neuronas en cada capa, tal como se puede observar en la tabla 6.2.

Resultados de la clasificación: De las 81 redes neuronales entrenadas se escoge aquella que presente los mejores resultados en la clasificación, los cuales se pueden determinar midiendo el coeficiente de correlación (r) entre las salidas de la red y los datos esperados y, el error cuadrático medio (rms). Este procedimiento sistemático permitió encontrar una arquitectura de red que permitiera realizar la clasificar los estados de maduración con la mayor precisión. En general la mayoría de las redes neuronales mostraron un comportamiento aceptable, pero se escogió aquella que tuviese la mayor precisión. La red neuronal mostró una mayor precisión en la clasificación de las mandarinas, como se evidencia en la tabla 6.2 es aquella que muestra los coeficientes de correlación (r) más alto y los errores cuadráticos medios (rms) más bajo.

En los resultados presentados en la tabla 6.2, se puede ver que todas las redes neuronales tienen un coeficiente de correlación superior al 0.98 en todas las combinaciones de capas ocultas, pero, una de las redes neuronales tiene el valor máximo de coeficiente de correlación (r) de 0.9936 para cuando la red tiene 57 neuronas en la primera capa oculta y 30 neuronas en la segunda capa oculta y así mismo, esta tiene el error cuadrático medio (rms) más bajo ($5.37\text{E-}02$). Estos altos valores de correlación indican que las componentes principales seleccionadas son altamente discriminantes y presentan una alta correlación con las clases de maduración definidas. Por tanto, la red neuronal que realiza la clasificación de los estados de maduración con la mayor precisión tiene una configuración 6:57:30:3, es decir, 6 neuronas en la capa de entrada, 57 y 30 neuronas en las primera y segunda capa oculta y 3 en la capa de salida. Las configuraciones de los pesos fueron establecidas por el algoritmo de entrenamiento fueron guardados, para el establecimiento de la red que realizará la clasificación.

Tabla 6.2: Coeficientes de correlación y error cuadrático medio para el establecimiento del número de neuronas ocultas por capa.

Capa 1	Capa 2	30	33	37	40	43	47	50	53	57	60
30	r	0.9924	0.9908	0.991	0.9892	0.9913	0.9841	0.9924	0.9875	0.9883	0.9886
	rms	5.80E-02	6.39E-02	6.34E-02	6.94E-02	6.21E-02	8.36E-02	5.83E-02	7.45E-02	7.22E-02	7.11E-02
33	r	0.9845	0.9924	0.9895	0.9867	0.9809	0.9859	0.9915	0.9889	0.9886	0.979
	rms	8.27E-02	5.82E-02	6.81E-02	7.71E-02	9.20E-02	7.91E-02	6.13E-02	7.01E-02	7.09E-02	9.64E-02
37	r	0.9934	0.9833	0.9901	0.9826	0.9867	0.9857	0.9784	0.989	0.9795	0.9868
	rms	5.42E-02	8.58E-02	6.64E-02	8.94E-02	7.67E-02	8.00E-02	9.88E-02	6.98E-02	9.57E-02	7.64E-02
40	r	0.9875	0.9836	0.9839	0.9903	0.9889	0.9904	0.9796	0.9877	0.9847	0.9803
	rms	7.46E-02	8.50E-02	8.43E-02	6.56E-02	7.01E-02	6.63E-02	9.48E-02	7.38E-02	8.22E-02	9.35E-02
43	r	0.9888	0.9834	0.9889	0.9865	0.9887	0.9842	0.9828	0.9836	0.9754	0.98
	rms	7.05E-02	8.57E-02	7.01E-02	7.73E-02	7.09E-02	8.36E-02	8.71E-02	8.51E-02	1.04E-01	9.38E-02
47	r	0.9906	0.9826	0.9897	0.9886	0.9903	0.9657	0.9817	0.9803	0.9804	0.9832
	rms	6.44E-02	8.93E-02	6.77E-02	7.09E-02	6.55E-02	1.25E-01	8.99E-02	9.31E-02	9.33E-02	8.63E-02
50	r	0.9896	0.9876	0.9916	0.9917	0.9898	0.9866	0.9925	0.9863	0.9887	0.9853
	rms	6.79E-02	7.41E-02	6.12E-02	6.09E-02	6.71E-02	7.72E-02	5.75E-02	7.77E-02	7.09E-02	8.07E-02
53	r	0.9884	0.9865	0.992	0.9878	0.9881	0.9911	0.9877	0.9904	0.9835	0.9876
	rms	7.16E-02	7.71E-02	6.00E-02	7.50E-02	7.26E-02	6.29E-02	7.38E-02	6.53E-02	8.54E-02	7.48E-02
57	r	0.9936	0.993	0.9866	0.9866	0.9903	0.986	0.992	0.9876	0.9861	0.989
	rms	5.37E-02	5.58E-02	7.75E-02	7.69E-02	6.56E-02	7.88E-02	5.96E-02	7.44E-02	7.84E-02	6.98E-02
60	r	0.9912	0.9884	0.9897	0.9915	0.9902	0.9881	0.9905	0.9824	0.9805	0.9776
	rms	6.24E-02	7.16E-02	6.88E-02	6.12E-02	6.58E-02	7.27E-02	6.51E-02	8.80E-02	9.28E-02	1.01E-01

Matriz de Confusión

La matriz de confusión es una herramienta utilizada principalmente en la clasificación y aprendizaje supervisado para evaluar el rendimiento de un modelo de clasificación. Se trata de una tabla que permite visualizar las predicciones de un modelo y compararlas con las verdaderas etiquetas o clases del conjunto de datos.

La idea de elaborar la matriz de confusión era evaluar cuantas veces la red neuronal acertaba o erraba al momento de seleccionar una clase. La matriz de confusión confronta las clases reales (filas) con las clases calculadas columnas. En nuestro caso la matriz de confusión obtenida es la contenida en la tabla 6.3.

Gráfico de Mapeo de Clasificación por Probabilidades (Matriz de confusión)

Tabla 6.3: Matriz de confusión para las tres clases de nuestro problema.

Matriz de Confusión	Verde	Pintón	Maduro
Verde	68	0	0
Pintón	0	44	0
Maduro	0	0	28

La matriz de confusión refleja la efectividad del modelo al clasificar las muestras en las categorías correctas. Los resultados obtenidos en la matriz de confusión muestran una precisión del 100%, con todos los elementos clasificados correctamente en su respectiva categoría:

Verde: 68 muestras fueron clasificadas correctamente como "Verde" sin errores de clasificación en otras categorías.

Pintón: 44 muestras fueron clasificadas como "Pintón", sin errores de confusión con las categorías "Verde" o "Maduro".

Maduro: 28 muestras fueron clasificadas correctamente como "Maduro".

Gráfico de Mapeo de Clasificación por Probabilidades




Figura 6.6 Mapeo de clasificación de muestra por probabilidades[Autor].

La figura 6.6 tridimensional muestra el mapeo de clasificación basado en las probabilidades de pertenencia a cada clase (tomando la clase con mayor probabilidad):

Ejes de Probabilidad: Los tres ejes representan las probabilidades asignadas a cada clase de maduración (Verde, Pinton y Maduro). Cada punto en el espacio corresponde a una muestra de cítrico clasificada por el modelo, donde su posición en el gráfico refleja su probabilidad de pertenecer a una clase específica.

Distribución de Muestras:

- **Verde** (puntos verdes): Se observa una agrupación en la zona de mayor probabilidad para la clase "Verde".
- **Pinton** (puntos amarillos): Las muestras correspondientes a esta categoría se distribuyen en el eje intermedio de probabilidades.

- **Maduro** (puntos rojos): Las muestras de frutas maduras están claramente separadas y alineadas con el eje de probabilidad de la clase "Maduro"

La separación clara entre los puntos de cada clase indica que el modelo ha logrado diferenciar adecuadamente entre las etapas de maduración de las frutas. Este mapeo de probabilidades respalda la precisión en la clasificación del modelo y demuestra su capacidad para asignar probabilidades distintas a cada clase, evitando ambigüedades.

Comparación de Resultados con Métodos Manuales

El sistema propuesto se comparó con métodos manuales tradicionales para evaluar su rendimiento en términos de precisión, velocidad y consistencia en la clasificación de frutos cítricos.

Los métodos manuales de inspección de frutos presentan varias limitaciones, como una velocidad de procesamiento relativamente lenta y una dependencia de la experiencia y juicio del evaluador, lo que introduce subjetividad y posibles inconsistencias en los resultados.

En contraste, el sistema hiperespectral propuesto logró una precisión notablemente alta, superando las capacidades de los métodos manuales y aumentando significativamente la eficiencia del proceso de clasificación. Además, el sistema hiperespectral es no destructivo y escalable, lo que lo hace adecuado para su integración en líneas de producción automatizadas.

Los resultados obtenidos demuestran que el sistema hiperespectral propuesto ofrece mejoras significativas en precisión y velocidad en comparación con los métodos manuales. Su capacidad para integrar datos espectrales con algoritmos Levenberg-Marquardt backpropagation posiciona esta solución como una herramienta avanzada y eficiente para la clasificación de frutos cítricos.

7. Conclusiones

La investigación alcanzó los objetivos planteados mediante una metodología basada en imágenes hiperespectrales y redes neuronales profundas, aplicadas a la clasificación y evaluación del estado de maduración de frutos cítricos, en particular mandarinas.

Se desarrolló un sistema de clasificación con una cámara hiperespectral Specim FX10e (400 a 1000 nm), que permitió registrar seis datacubos hiperespectrales. A través del procesamiento digital de imágenes, la reducción de la dimensionalidad de los espectros y la implementación de redes neuronales, se logró clasificar las mandarinas en tres estados de maduración: verde, pintón y maduro.

Se implementó un algoritmo de procesamiento digital de imágenes que permite extraer el espectro de cada mandarina. Este incluye una etapa de segmentación y aislamiento de la zona correspondiente a cada objeto, lo que posibilita la extracción individual de las firmas espectrales.

Mediante el Análisis de Componentes Principales (PCA), se redujo la dimensionalidad de las firmas espectrales de 448 bandas a 15 componentes principales. Se seleccionaron las seis primeras, conservando el 97 % de la información relevante.

Se implementaron y entrenaron 81 redes neuronales profundas utilizando el algoritmo Levenberg-Marquardt backpropagation. Se seleccionó la arquitectura óptima (6:57:30:3), correspondiente a una red de cuatro capas: una de entrada con seis neuronas, dos ocultas de 57 y 30 neuronas respectivamente, y una de salida con tres neuronas. Esta red presentó el mejor desempeño en la clasificación de los estados de maduración, con un coeficiente de correlación de 0.9936 y un error cuadrático medio de 0.0537, lo que demuestra su eficacia para distinguir entre mandarinas verdes, pintonas y maduras.

Para evaluar la efectividad de la red neuronal seleccionada, se calculó la matriz de confusión (Tabla 6.3), que reveló una precisión del 100% en la clasificación de los estados de maduración, sin errores entre las categorías verde, pintón y maduro.

Este sistema es una herramienta útil para la industria de los cítricos, ya que permite una clasificación precisa y no destructiva de mandarinas según su estado de maduración. La metodología desarrollada ofrece beneficios importantes en la optimización de la inspección y selección en líneas de producción, asegurando que solo las frutas en óptimas condiciones de maduración lleguen al consumidor.

No se realizaron comparaciones adicionales con otros métodos o tecnologías, ya que la metodología implementada toma como referencia las habilidades desarrolladas por agricultores expertos para la clasificación.

Como perspectiva para futuros trabajos, se propone explorar otras técnicas, como redes neuronales profundas (Deep Learning), incluyendo redes convolucionales (CNN) y métodos de aprendizaje automático (Machine Learning), lo que permitirá realizar comparaciones entre estas técnicas de inteligencia artificial.

8. Referencias

- [1] J. Blasco, N. Aleixos, y E. Moltó, “Machine vision system for automatic quality grading of fruit,” *Biosyst. Eng.*, vol. 103, no. 1, pp. 29–39, 2009, doi: 10.1016/j.biosystemseng.2009.02.007.
- [2] Y. Huang, C. Zhang, y X. Li, “Hyperspectral imaging technology for food quality assessment: Principles, applications, and trends,” *Trends Food Sci. Technol.*, vol. 118, pp. 1–11, 2021, doi: 10.1016/j.tifs.2021.08.008.
- [3] A. A. Gowen et al., “Hyperspectral imaging—An emerging process analytical tool for food quality and safety control,” *Food Bioprocess Technol.*, vol. 18, no. 12, pp. 590–598, 2007.
- [4] E. Hecht, *Optics*, 5th ed. Pearson Education, 2017.
- [5] J. Yang et al., “A deep learning approach to improving spectral analysis of fruit quality under interseason variation,” *Food Control*, vol. 140, 2022, doi: 10.1016/j.foodcont.2022.109123.
- [6] I. Newton, *Opticks*. Londres, Inglaterra: William Innys, 1704.
- [7] J. von Fraunhofer, “On the lines observed in the spectrum of the sun,” *Ann. Philos.*, vol. 4, pp. 269–282, 1814.
- [8] H. P. K.K., *Photomultiplier Tubes: Basics and Applications*, Third Edition. Hamamatsu, Japón: Hamamatsu Photonics K.K., 2006.
- [9] J. R. Janesick et al., “Scientific Charge-Coupled Devices,” *Opt. Eng.*, vol. 26, no. 8, p. 268692, 1987.
- [10] D. Landgrebe, *Signal Theory Methods in Multispectral Remote Sensing*. Hoboken, NJ, EE.UU.: John Wiley & Sons, 2003.
- [11] M. J. Khan et al., “Modern Trends in Hyperspectral Image Analysis: A Review,” *IEEE Access*, vol. 6, pp. 14118–14129, 2018, doi: 10.1109/ACCESS.2018.2819311.
- [12] S. Schweizer y J. Moura, “Efficient detection in hyperspectral imagery,” *IEEE Trans. Image Process.*, vol. 10, pp. 584–597, 2001, doi: 10.1109/83.913601.
- [13] Y.-R. Chen, K. Chao, y M. Kim, “Machine vision technology for agricultural applications,” *Comput. Electron. Agric.*, vol. 36, no. 2, pp. 173–191, 2002.
- [14] M. Kim et al., “Multispectral detection of fecal contamination on apples based on hyperspectral imagery: Part I. Application of visible and near-infrared reflectance imaging,” *Trans. ASAE*, vol. 45, pp. 2027–2037, 2002.
- [15] P. Mehl, Y. Chen, M. Kim, y D. Chan, “Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations,” *J. Food Eng.*, vol. 61, pp. 67–81, 2004.
- [16] M. Nagata et al., “NIR hyperspectral imaging for measurement of internal quality in strawberries,” in *ASAE Annu. Int. Meeting*, Tampa, FL, USA, 2005.
- [17] K. Lee et al., “Hyperspectral imaging for detecting defect on apples,” in *ASAE Annu. Int. Meeting*, Tampa, FL, USA, 2005.

- [18] J. Xing et al., “Wavelength selection for surface defects detection on tomatoes by means of a hyperspectral imaging system,” in *ASABE Annu. Int. Meeting*, Portland, OR, USA, 2006.
- [19] J. Abbott, “Quality measurement of fruits and vegetables,” *Postharvest Biol. Technol.*, vol. 15, pp. 207–225, 1999.
- [20] M. Abdullah et al., “The applications of computer vision system and tomographic radar imaging for assessing physical properties of food,” *J. Food Eng.*, vol. 61, pp. 125–135, 2004.
- [21] M. Aikio, *Hyperspectral Prism–Grating–Prism Imaging Spectrograph*, vol. 435, Espoo, Finland: VTT Publications, 2001. [En línea]. Disponible en: <https://cris.vtt.fi/en/publications/hyperspectral-prism-grating-prism-imaging-spectrograph-dissertati>
- [22] K. Chao et al., “Chicken heart disease characterization by multi-spectral imaging,” *Appl. Eng. Agric.*, vol. 17, pp. 99–106, 2001.
- [23] C. Pasquini, “Near infrared spectroscopy: fundamentals, practical aspects and analytical applications,” *J. Braz. Chem. Soc.*, vol. 14, pp. 198–219, 2003, doi: 10.1590/S0103-50532003000200006.
- [24] R. Schowengerdt, *Remote sensing: models and methods for image processing*, 2nd ed. San Diego, CA: Academic Press, 1997.
- [25] “Hyperspectral and Multispectral Imaging.” [En línea]. Disponible en: <https://www.pyroistech.com/hyperspectral-and-multispectral-imaging/>.
- [26] «Luz Espectro Electromagnética». [En línea]. Disponible en: <https://www.goconqr.com/mapamental/3345506/luz-espectro-electromagnetica>
- [27] «Espectrometría de Infrarrojo Cercano (NIR)». [En línea]. Disponible en: <https://ilion.com.uy/webinars/espectrometria-de-infrarrojo-cercano-nir/>
- [28] J. Blasco, N. Aleixos, J. Gomez-Sanchis, y E. Moltó, “Citrus sorting by identification of the most common defects using multispectral computer vision,” *J. Food Eng.*, vol. 83, no. 3, pp. 384–393, 2007, doi: 10.1016/j.jfoodeng.2007.03.006.
- [29] L. Jiang, B. Zhu, y Y. Tao, “Hyperspectral Image Classification Methods,” en *Hyperspectral Imaging for Food Quality Analysis and Control*, Elsevier Inc., 2010, pp. 79–100.
- [30] M. Born y E. Wolf, *Principles of Optics*, 7th ed. Cambridge University Press, 1999.
- [31] C. F. Bohren y D. R. Huffman, *Absorption and Scattering of Light by Small Particles*. Wiley-VCH, 2004.
- [32] F. L. Pedrotti, L. S. Pedrotti, y L. M. Pedrotti, *Introduction to Optics*. Cambridge University Press, 2017.
- [33] J. D. Jackson, *Classical Electrodynamics*, 3rd ed. Wiley, 1998.
- [34] A. Z. Akhmediev y N. N. Akhmediev, *Optical Wave Scattering*. Academic Press, 2009.
- [35] J. A. Stratton, *Electromagnetic Theory*. McGraw-Hill, 1941.
- [36] J. Qin, “Hyperspectral Imaging Instruments,” en *Hyperspectral Imaging for Food Quality Analysis and Control*, 1st ed., Elsevier, 2010, pp. 129–153.

- [37] J. Qin, "Using Hyperspectral Imaging for Food Quality Evaluation," en *Hyperspectral Imaging for Food Quality Analysis and Control*, 1st ed., Elsevier, 2010, pp. 365–384.
- [38] J. Qin, T. Burks, M. Ritenour, y W. Bonn, "Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence," *J. Food Eng.*, vol. 93, no. 2, pp. 183–191, 2009.
- [39] D. Sun, Ed., *Infrared spectroscopy for food quality analysis and control*. San Diego, CA: Academic Press/Elsevier, 2008.
- [40] C. Palmer y E. Loewen, *Diffraction Grating Handbook*, 8th ed. Newport Corporation, 2005.
- [41] G. ElMasry y D.-W. Sun, "CHAPTER 1 - Principles of Hyperspectral Imaging Technology," en *Hyperspectral Imaging for Food Quality Analysis and Control*, D.-W. Sun, Ed. San Diego: Academic Press, 2010, pp. 3–43, doi: 10.1016/B978-0-12-374753-2.10001-2.
- [42] C. Du y D.-W. Sun, "Recent developments in the applications of image processing techniques for food quality evaluation," *Trends Food Sci. Technol.*, vol. 15, pp. 230–249, 2004.
- [43] J. Qin y R. Lu, "Measurement of the absorption and scattering properties of turbid liquid foods using hyperspectral imaging," *Appl. Spectrosc.*, vol. 61, no. 4, pp. 388–396, 2007.
- [44] R. Lu y Y. Chen, "Hyperspectral imaging for safety inspection of food and agricultural products," en *Pathogen Detection and Remediation for Safe Eating, Proc. SPIE*, 1998, pp. 121–133.
- [45] R. Lu, "Detection of bruises on apples using near-infrared hyperspectral imaging," *Trans. ASAE*, vol. 46, no. 2, pp. 523–530, 2003.
- [46] R. Lu y B. Park, "Hyperspectral and multispectral imaging for food quality and safety," *Sens. Instrum. Food Qual. Saf.*, vol. 2, no. 3, pp. 131–132, 2008.
- [47] C. B. Singh, J. Paliwal, D. S. Jayas, y N. D. G. White, *Near-infrared spectroscopy: applications in the grain industry*. Winnipeg: CSBE, 2006.
- [48] J. Qin y R. Lu, "Measurement of the optical properties of fruits and vegetables using spatially resolved hyperspectral diffuse reflectance imaging technique," *Postharvest Biol. Technol.*, vol. 49, no. 3, pp. 355–365, 2008.
- [49] J. Gomez-Sanchis *et al.*, "Hyperspectral system for early detection of rottenness caused by *Penicillium digitatum* in mandarins," *J. Food Eng.*, vol. 89, no. 1, pp. 80–86, 2008.
- [50] D. Hurtado, "Evaluation of near-infrared spectroscopy for citrus fruit quality assessment," 2024. [En línea]. Disponible en: <https://repositorio.usc.edu.co/items/211f9c41-e674-4a56-8493-97b8d2329cce>.
- [51] D. Lorente *et al.*, "Automatic detection of citrus rotting diseases using VNIR spectroscopy and machine learning," *Postharvest Biol. Technol.*, vol. 122, pp. 9–17, 2016.