



CENTRO DE INGENIERÍA Y DESARROLLO  
INDUSTRIAL

---

---

SISTEMA INTELIGENTE PARA DETECCIÓN  
TEMPRANA DE LA ROYA EN CAFETALES

**TESIS**

QUE PARA OBTENER EL GRADO ACADEMICO DE:

MAESTRO EN CIENCIA Y TECNOLOGÍA EN LA ESPECIALIDAD  
DE MECATRÓNICA

PRESENTA:

JULIO CÉSAR GAVITO MUÑOZ

TUTOR

M. SC. ROBERTO SOSA CRUZ



SANTIAGO DE QUERÉTARO, QRO., ABRIL 2019

*Dedicatoria*

Dedicada a mi familia, quienes fueron el mayor soporte durante este complicado proceso.

# Agradecimientos

Agradezco profundamente a todos los que han contribuido a la culminación de esta Tesis, en primer lugar a mis padres y a mi hermano, quienes apoyaron mi deseo de la búsqueda del conocimiento científico así como tuvieron la paciencia para escuchar mis ideas.

Agradezco a CIDESI por permitirme el uso de sus instalaciones, tanto de la sede Querétaro como la sede Estado de México, para llevar a cabo la experimentación así la investigación documental necesaria para la obtención del grado.

Agradezco a CONACYT por la oportunidad de realizar estudios de posgrado así como la beca que me fue otorgada para la realización de los mismos.

Un agradecimiento especial a mi tutor y amigo Roberto Sosa, que gracias a sus consejos fue posible la culminación de las diferentes etapas de la Tesis.

Agradezco el apoyo prestado por la Ing. Nayeli Ortiz, quién forma parte del Comité Estatal de Sanidad Vegetal del Estado de Querétaro, en la recolección de muestras de hojas de café en Landa de Matamoros, Querétaro.

Finalmente agradezco al personal de CIDESI quienes se vieron involucrados en este proyecto, en especial a la Lic. Alicia Márquez y a la M. Bertha Velasco, quienes apoyaron la conclusión de esta Tesis de manera cercana.

# Resumen

La presente Tesis habla acerca del desarrollo de un sistema experto capaz de identificar la roya (*Hemileia Vastatrix*) que presentan hojas de café, siendo esta una de las enfermedades más destructivas para la planta. El desarrollo de este proyecto es importante por el lugar que ocupa el café en México como cultivo de alto valor al ser de los principales productores a nivel mundial. La metodología de solución plantea el uso de imágenes hiperespectrales para realizar un análisis a detalle de las hojas, para procesarlas se utilizan índices de vegetación para mejorar la discriminación entre zonas con clorofila y las que se encuentran dañadas. Utilizando algoritmos de *machine learning*, se separan las hojas en diferentes clases según el grado de daño; esta escala elaborada por la SAGARPA, ahora SADER, poniendo especial atención en las que se encuentran en etapas tempranas del desarrollo de la enfermedad. La experimentación mostró que es posible hacer identificación en etapas tempranas, lo que con ayuda de los expertos de sanidad vegetal permitirá rápidas acciones de control de la enfermedad.

# Abstract

This Thesis is about the development of an expert system capable of identifying the coffee rust (*Hemileia Vastatrix*), being one of the most destructive diseases regarding the coffee plants. The development of this project is important due the relevant place that has the coffee in Mexico as one of the high value crops for the country and one of the mayor consumed drinks in the world. The methodology solution states that with the use of hyperspectral imaging is possible to make an analysis in detail of the coffee leaves, the images are processed using vegetation indices to enhance the discrimination among zones with chlorophyll and the zones that lack of it would mean that is damaged. With the use of machine learning algorithms, the leaf images are separated in different classes regarding the damage degree; according to a scale elaborated by SAGARPA (now SADER) part of the Mexican Government, with special focus on the ones that has lower levels of coffee rust infection. The experiments showed that is possible to have an the early state detection of coffee rust and that will allow early disease control actions from the vegetation experts, like agronomers or phytopathologists.

# Índice general

<b>Agradecimientos</b>	<b>II</b>
<b>Resumen</b>	<b>III</b>
<b>Abstract</b>	<b>IV</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Antecedentes . . . . .	2
1.2. Definición del tema . . . . .	3
1.3. Justificación . . . . .	5
1.4. Objetivos . . . . .	6
1.5. Hipótesis . . . . .	7
<b>2. Fundamentación</b>	<b>8</b>
2.1. Machine Learning . . . . .	8
2.2. Aprendizaje supervisado . . . . .	12
2.3. Support Vector Machine . . . . .	13
2.4. Random Forest . . . . .	15
2.5. Redes Neuronales . . . . .	17
2.6. Aprendizaje no supervisado . . . . .	20
2.7. Principal Component Analysis . . . . .	21
2.8. Evaluación de métodos . . . . .	22
2.9. Imágenes hiperespectrales . . . . .	24

<i>ÍNDICE GENERAL</i>	VI
2.10. Índices de vegetación . . . . .	26
<b>3. Metodología</b>	<b>30</b>
3.1. Diagrama de flujo de la metodología . . . . .	31
3.2. Selección de la cámara . . . . .	32
3.3. Consolidación del banco de pruebas . . . . .	34
3.4. Recolección de muestras . . . . .	38
3.5. Procesamiento de las imágenes . . . . .	39
<b>4. Resultados</b>	<b>46</b>
4.1. Resultados NDVI . . . . .	46
4.2. Resultados RDVI . . . . .	49
4.3. Resultados EVI . . . . .	53
4.4. Resultados NDVI705 . . . . .	56
4.5. Resultados NDVIrededge . . . . .	59
<b>5. Conclusiones</b>	<b>63</b>
<b>6. Recomendaciones</b>	<b>65</b>
<b>Bibliografía</b>	<b>65</b>

# Índice de figuras

2.1. Ejemplos de información que se pueden usar como información para un algoritmo	9
2.2. Diagrama de flujo del proceso general de <i>machine learning</i>	10
2.3. Subentrenamiento vs Modelo correctamente ajustado	11
2.4. Modelo correctamente ajustado vs Sobreentrenamiento	11
2.5. Ejemplo de la aplicación de un algoritmo de aprendizaje supervisado	12
2.6. Ejemplo de la gráfica producida por un algoritmo de SVM	14
2.7. Árbol de decisiones para un problema de clasificación de diferentes especies de la flor Iris	16
2.8. Ejemplo de regiones de decisión generadas por un algoritmo de RF.	16
2.9. Estructura básica de una red neuronal	17
2.10. Estructura básica de un perceptrón	18
2.11. Ejemplo de la aplicación de agrupamiento	20
2.12. Transformaciones al aplicar PCA	22
2.13. Espectro electromagnético, la longitud de onda ( $\lambda$ ) en metros	25
2.14. Estructura de un hipercubo	26
2.15. Técnicas de adquisición de fotografías espectrales	27
3.1. Diagrama de flujo de la metodología seguida	31
3.2. Cámara MQ022HG-IM-LS100-NIR	32
3.3. Sensor CMV2000	32
3.4. Interferómetro de Fabry-Pérot	33
3.5. Distribución de las bandas espectrales en la cámara MQ022HG-LS100-NIR	33



3.6. Lente #67-716 de Edmund Optics . . . . .	34
3.7. Banco de pruebas basado en una mesa cartesiana . . . . .	35
3.8. Piezas del soporte diseñado para sostener la cámara . . . . .	36
3.9. Prueba de iluminación . . . . .	36
3.10. Imagen RAW sin corrección de la cámara . . . . .	37
3.11. Imagen al aplicarse la FFC . . . . .	37
3.12. Hojas en una parcela de Puerto del Sabino, Landa de Matamoros, Querétaro	38
3.13. Escala de daño según el porcentaje de infección . . . . .	38
3.14. Hojas de café colocadas en la prensa botánica . . . . .	39
3.15. Proceso de escaneo de hojas . . . . .	40
3.16. Imagen sin traslape vs. Imagen con traslape, ambas con un pseudo coloreado	41
3.17. Bandas espectrales sin alinear vs alineadas. . . . .	41
3.18. NDVI de una hoja . . . . .	42
3.19. PCA de 2 y 3 componentes con NDVI . . . . .	43
3.20. PCA de 2 y 3 componentes con RDVI . . . . .	44
3.21. PCA de 2 y 3 componentes con EVI . . . . .	44
3.22. PCA de 2 y 3 componentes con NDVI705 . . . . .	45
3.23. PCA de 2 y 3 componentes con NDVIrededge . . . . .	45
4.1. Diagrama de cajas con el desempeño de los algoritmos al emplear NDVI . . .	47
4.2. Resultados de la matriz de confusión del RF utilizando NDVI . . . . .	47
4.3. Resultados de la matriz de confusión del SVM utilizando NDVI . . . . .	48
4.4. Resultados de la matriz de confusión de la ANN utilizando NDVI . . . . .	49
4.5. Diagrama de cajas con el desempeño de los algoritmos al emplear RDVI . . .	50
4.6. Resultados de la matriz de confusión de RF utilizando RDVI . . . . .	51
4.7. Resultados de la matriz de confusión de SVM utilizando RDVI . . . . .	52
4.8. Resultados de la matriz de confusión de ANN utilizando RDVI . . . . .	53
4.9. Diagrama de cajas con el desempeño de los algoritmos al emplear EVI . . . .	54
4.10. Resultados de la matriz de confusión de RF utilizando EVI . . . . .	54
4.11. Resultados de la matriz de confusión de SVM utilizando EVI . . . . .	55

4.12. Resultados de la matriz de confusión de ANN utilizando EVI . . . . .	56
4.13. Diagrama de cajas con el desempeño de los algoritmos al emplear NDVI705 .	57
4.14. Resultados de la matriz de confusión de RF utilizando NDVI705 . . . . .	58
4.15. Resultados de la matriz de confusión de SVM utilizando NDVI705 . . . . .	58
4.16. Resultados de la matriz de confusión de ANN utilizando NDVI705 . . . . .	59
4.17. Diagrama de cajas con el desempeño de los algoritmos al emplear NDVIrededge	60
4.18. Resultados de la matriz de confusión de RF utilizando NDVIrededge . . . . .	61
4.19. Resultados de la matriz de confusión de SVM utilizando NDVIrededge . . .	61
4.20. Resultados de la matriz de confusión de ANN utilizando NDVIrededge . . .	62

# Índice de tablas

2.1. Matriz de confusión para dos clases. . . . .	23
3.1. Características del lente #67-716 de Edmund Optics . . . . .	34
3.2. Detalle de las muestras de hojas con y sin roya . . . . .	39
4.1. Tabla de métricas de RF utilizando NDVI . . . . .	48
4.2. Tabla de métricas de SVM utilizando NDVI . . . . .	48
4.3. Tabla de métricas de ANN utilizando NDVI . . . . .	49
4.4. Tabla de métricas de RF utilizando RDVI . . . . .	50
4.5. Tabla de métricas de SVM utilizando RDVI . . . . .	51
4.6. Tabla de métricas de ANN utilizando RDVI . . . . .	52
4.7. Tabla de métricas de RF utilizando EVI . . . . .	55
4.8. Tabla de métricas de SVM utilizando EVI . . . . .	55
4.9. Tabla de métricas de ANN utilizando EVI . . . . .	56
4.10. Tabla de métricas de RF utilizando NDVI705 . . . . .	57
4.11. Tabla de métricas de SVM utilizando NDVI705 . . . . .	59
4.12. Tabla de métricas de ANN utilizando NDVI705 . . . . .	59
4.13. Tabla de métricas de RF utilizando NDVIrededge . . . . .	60
4.14. Tabla de métricas de SVM utilizando NDVIrededge . . . . .	62
4.15. Tabla de métricas de ANN utilizando NDVIrededge . . . . .	62

# Capítulo 1

## Introducción

A nivel mundial, el café es uno de los cultivos con mayor valor ya que genera 90 mil millones de dólares cada año y le da empleo por lo menos a 500 millones de personas[1]. Sin embargo, la existencia de agentes dañinos para las plantas como hongos provoca pérdidas millonarias para los productores.

La roya del café es una de las enfermedades más conocidas ya que fue de las primeras enfermedades en ser estudiada de manera científica[2]. Es provocada por el hongo *Hemileia vastatrix*, y en los últimos años ha empezado a tener una presencia importante en América Latina, lo que se puede traducir en una disminución de la capacidad de producción así como considerables pérdidas económicas[3].

A la fecha el método tradicional para detección de la roya consiste en la inspección visual de la planta en búsqueda de signos que muestren la aparición de la enfermedad, lo que se convierte en un proceso que consume tiempo por las extensiones de las huertas. Para hacer más eficiente la tarea se han comenzado a desarrollar nuevas técnicas que implementen acciones para mitigar el daño, entre ella es una identificación de la aparición de la enfermedad en etapas tempranas para un correcto tratamiento.

Una de las soluciones que se han propuesto ha sido el uso de imágenes generadas con sensores con la tecnología más reciente en óptica, que permiten detectar deficiencias en la planta así como la defoliación[4]. La interacción de las hojas con las ondas electromagnéticas de la luz ha propiciado el uso de imágenes espectrales, ya que es posible caracterizar la salud de la

planta según la reflectividad de las hojas [5].

El conjunto de imágenes generado por los sensores hiperespectrales, llamado hipercubo, dificulta la posibilidad de utilizar la información ya que se vuelve redundante, por lo que es necesario emplear algoritmos que permitan disminuir la cantidad de información y que al mismo tiempo permita procesarla [6], entre estos se destacan los que pertenecen al *machine learning* como el Análisis de Componentes Principales, para la reducción dimensional de la información, y las Máquinas de Vector de Soporte, para generar un modelo matemático que permita la clasificación de información.

Adicionalmente de los algoritmos, otra herramienta utilizada para facilitar el análisis de imágenes son los índices de vegetación, que nos permiten conocer información de las características físicas de las plantas, por ejemplo la cantidad de clorofila con las que cuentan [7]. Esto se debe a que utilizan la reflectancia proporcionada por las imágenes hiperespectrales en dos o más bandas y se realiza normalizaciones que permiten hacer una mejor diferencia entre la información obtenida.

Debido a que México forma parte de los 10 principales productores de café a nivel mundial, la creación de sistemas o paquetes tecnológicos que ayuden en la tarea de diagnosticar, identificar y combatir enfermedades tan destructivas como la roya del café tiene que convertirse en una tarea de suma importancia.

## 1.1. Antecedentes

A continuación se enlistan algunos trabajos que se han realizado en el campo de la detección de enfermedades, tanto roya del café como algunas similares, estos han servido para fundamentar el proyecto y tomarlos como referencia.

En 2016 Wei Feng et al. [8] realizaron un trabajo que tiene como objetivo estimar la severidad del daño provocada por el oídio; un hongo similar a la roya, que hace aparecer manchas blancas que se transforman en un polvillo blanco, en trigo. Para detectarlo se utilizó la reflectancia de las hojas en el rango de los 400 a los 1000 nanómetros (nm) para el cálculo de una serie de índices de vegetación, mostrando como conclusión que cuando se encuentran

infectadas las hojas la reflectancia es baja.

En [9] Wenjiang Huang et al. investigan un método para la identificación de roya de trigo, una enfermedad similar a la del café, ya que tiene síntomas similares ya que aparecen pústulas amarillas sobre las hojas. Debido a que el estado de salud de las plantas se encuentra muy relacionado a la cantidad de clorofila y su interacción con la reflectancia de luz propusieron el uso del índice de foto químico de reflectancia, PRI por sus siglas en inglés, para poder monitorear los cambios fisiológicos de las plantas y clasificar el grado de avance de la enfermedad.

Jayme Garcia Arnal Barbedo et al. en [10] se plantearon el uso de imágenes RGB para la identificación de enfermedades en diferentes plantas, a cada imagen se les aplican máscaras por medio de software para extraer diferentes canales. Para realizar la clasificación utiliza una correlación entre los histogramas que indican la intensidad de los píxeles que se utilizaron para entrenar el algoritmo, aproximadamente el 70 % de las fotos, y los de las imágenes que se emplearon para probar su efectividad. Concluyen que es un método que puede estar sujeto a mejoras ya que en reporta una serie de fallas en algunas clasificaciones.

Cora Pérez Ariza, Ann Nicholson y Julia Flores [11] presentaron parte de su investigación dónde buscan predecir la aparición de la roya del café con redes bayesianas, un tipo de algoritmo de *machine learning*. Sin embargo, el estudio se realizó con información recolectada durante 8 años en Brasil, por lo que las entradas del sistema eran datos como temperatura, humedad, velocidad del viento entre otros, a diferencia de lo que se propondrá en este trabajo que es a partir de imágenes estudiando la estructura física de las hojas. Concluyen que con esta metodología se pueden obtener resultados similares a en las 2 bases de datos que manejan, una donde es la información completa y en otra donde solo se usa una parte de ellos previamente seleccionados.

## 1.2. Definición del tema

Actualmente la inteligencia artificial se encuentra en un gran crecimiento provocado por el constante incremento de la capacidad y la velocidad de cómputo de los equipos más mo-

ernos. Un área que ha llamado enormemente la atención es el *machine learning*, destacada por elaborar programas que puedan aprender utilizando información previa que podríamos considerar experiencia, similar a como aprendemos los humanos.

Debido a esta capacidad se propuso la creación de un sistema de inteligencia artificial, basado en *machine learning* que sea capaz clasificar el grado de afectación de la roya del café en la planta. México al ser uno de los países en el mundo que se dedica a la producción café ha sido afectado por la presencia de este hongo desde 1981, la dificultad de detectarlo en etapas tempranas ha permitido que se haya propagado y esto genera pérdidas monetarias.

Hasta la fecha, el método para el diagnóstico más utilizado continua siendo la inspección visual por parte del agricultor con apoyo de personal de las oficinas de gobierno encargadas de la sanidad vegetal, pese a lo que se invierte en tiempo para realizar esta actividad el error humano continua siendo común lo que provoca errores de identificación. Otro método que se ha comenzado a utilizar en México es el monitoreo utilizando imágenes satelitales de ciertas parcelas, lo que no es suficiente porque gran parte de los productores se quedan desprotegidos contra el hongo.

En el manejo del café, la oportuna identificación de la aparición de la roya forma parte esencial en el éxito del control de esta enfermedad. Para poder combatirla es necesario el uso de fungicidas, como por ejemplo ciproconazol o el oxiclورو de cobre [13], que deben ser aplicados en ciertas épocas del año, una vez se ha identificado que la roya ha comenzado a desarrollarse, si la aplicación de la primera dosis no se hace en el momento adecuado las siguientes no tendrán efecto.

Por desgracia ambos métodos tienen desventajas, en el caso de la inspección visual se requiere que se revisen las hectáreas de café empleando una técnica llamada Cinco de Oros, donde se revisan 5 plantas en cada una de las esquinas y en el centro de la parcela; verificando hojas de la parte superior, media e inferior, esto provoca que el muestreo sea aleatorio y la clasificación del daño quede a consideración del evaluador, lo que vuelve este estudio subjetivo.

Con las imágenes satelitales existen algunos inconvenientes, el primero de ellos es que el acceso a imágenes se encuentra restringido por lo que es necesario realizar un pago, como se puede ver en [14] para imágenes de alta resolución hay costos entre 24 y 29 USD para

imágenes recientes, y la superficie mínima es de  $100 \text{ km}^2$ , lo que equivale a 10,000 hectáreas, aquí es donde aparece el segundo inconveniente, la resolución de estas imágenes es de 50 metros por píxel, por lo que es posible que se pierda mucha información.

En investigación se ha utilizado una alternativa gratuita para la adquisición de imágenes, los satélites Landsat del Servicio Geológico de los Estados Unidos (USGS) y los Sentinel de la Agencia Espacial Europea (ESA). De ambos satélites es posible la adquisición de imágenes de manera gratuita, sin embargo el problema de estos satélites es el tiempo que tardan en hacer una visita por el mismo punto, en el caso del Landsat-8 tarda 16 días [15] y el Sentinel-2 tarda 5 días [16], además es importante considerar la posible aparición de nubes que impidan la visibilidad.

El uso combinado de las mejores prácticas de ambas técnicas permite la creación de un sistema que puede realizar la tarea de diagnosticar la severidad de la roya de una manera más eficiente, ya que un sistema que utilice inteligencia artificial para realizar la cuantificación del daño de la roya en las hojas basado en imágenes espectrales permite eliminar el factor subjetivo en la toma de decisiones.

### 1.3. Justificación

Con este proyecto, se genera un sistema que, empleando un algoritmo de *machine learning* y utilizando imágenes hiperespectrales sea capaz de identificar la infección de los cafetales con el hongo de la roya e informar el grado de severidad en el que se encuentra, para que, el agricultor tome las medidas adecuadas en la aplicación de fungicidas y evitar su propagación. Con la rápida detección de la enfermedad de la planta se busca disminuir el efecto negativo que genera sobre el café en dos aspectos principales, combatir la pérdida de plantas productivas de así como para combatir la propagación y expansión de la plaga en plantíos cercanos o lejanos, ya que las esporas del hongo son arrastradas por el viento y pueden alcanzar hectáreas lejanas.[17]

México al ser uno de los productores más importantes de café en el mundo, necesita el desarrollo de paquetes tecnológicos que permitan incrementar la productividad y la rentabilidad



del café de una manera sustentable. Según el Atlas Agroalimentario, publicación elaborada por el Servicio de Información Agroalimentaria y Pesquera del Gobierno de México (SIAP), la producción en de café en 2018 se redujo un 37.4% con respecto a la producción de 6 años atrás, lo que se traduce de una reducción de 1.33 millones a 835,000 de toneladas, siendo la roya la principal causa de esta caída. [18]

En este proyecto, se está innovando en la forma de inspeccionar el café, ya que, actualmente se hace de dos formas; La primera, es la inspección visual en donde entra en juego el factor humano como origen de posibles errores al momento de la revisión. La segunda, es la inspección por satélite donde la problemática, es el tiempo para adquirir una imagen que muestre de manera significativa las condiciones del lugar de estudio.

El método inspección propuesto en esta tesis se distingue por realizar la adquisición de imágenes utilizando cámaras hiperspectrales de las hojas de la planta, para realizar una clasificación del grado de daño utilizando un algoritmo de *machine learning* que emplee índices de vegetación como información de entrada para determinar el porcentaje de infección en las hojas.

## 1.4. Objetivos

- Objetivo General

Desarrollar un sistema experto que implemente *machine learning* a través de imágenes hiperspectrales, que permita la identificación y clasificación de las diferentes etapas de la roya del café para establecer un diagnóstico temprano.

- Objetivos específicos

1. Construcción de un banco de pruebas que permita la obtención de imágenes hiperspectrales de hojas de café.
2. Generación de hipercubos que contengan la firma espectral de diferentes hojas de café en diferentes estados.

3. Elaboración de un programa que permita procesar las imágenes hiperespectrales para la adquisición de diferentes índices de vegetación.
4. Conformación de una base de datos utilizando imágenes hiperespectrales para ser utilizadas como datos de entrada para entrenar un algoritmo de *machine learning*.
5. Desarrollo de un algoritmo *machine learning* que permita la identificación de roya usando el sistema de cámaras.
6. Validación del algoritmo mediante pruebas en laboratorio.

## 1.5. Hipótesis

Utilizando algoritmos de machine learning se puede hacer un sistema que permita la clasificación del estado de la planta en el que se encuentre, y que se pueda tomar acciones para combatir la propagación de la enfermedad.

# Capítulo 2

## Fundamentación

En la siguiente sección se describirán conocimientos necesarios para comprender el experimento de manera holística. Se describe lo que es *machine learning*, los problemas que se pueden resolver y como se debe procesar la información para que los algoritmos sean aplicados después de la revisión bibliográfica.

Se describirá de una manera general la manera en que los algoritmos toman acción así como se hará una descripción más detallada de los algoritmos que fueron elegidos para esta Tesis ya que presentan una serie de condiciones favorables para encontrar la mejor solución, además parte del preprocesamiento que será empleado en dos de los algoritmos seleccionados.

Finalmente se explicará el concepto de imágenes hiperespectrales, como obtenerlas y como se puede realizar una interpretación para el uso de los índices de vegetación como herramientas para hacer una discriminación más efectiva entre las diferentes clases que serán obtenidas como resultado de la aplicación del algoritmo.

### 2.1. Machine Learning

Resolver problemas por medio de la computadora suele no ser una tarea sencilla por una serie de factores, en primer lugar es necesario contar con un algoritmo, que en otras palabras significa tener una serie de instrucciones que permite transformar información de entrada en una salida que pueden ser más datos o acciones específicas.

En segundo lugar, contar con información suficiente para procesar una decisión mediante un algoritmo es otro aspecto vital, que gracias a la era de la información se ha podido solucionar en gran medida ya que el internet es una gran fuente. Incluso existen bases de datos que es posible descargar para poder entrenarse en el uso de algoritmos.

En el caso de no disponer con la información necesaria y no poder conseguirla se procede a hacer una recolección. Dependiendo del tipo de problema la información se puede representar de diferentes formas. En la Figura 2.1 se pueden ver ejemplos de representación por ejemplo en texto se puede contar la ocurrencia de las palabras, si es una imagen cada píxel se convierte en un dato o si se desea describir un objeto se crean categorías para ciertas características.

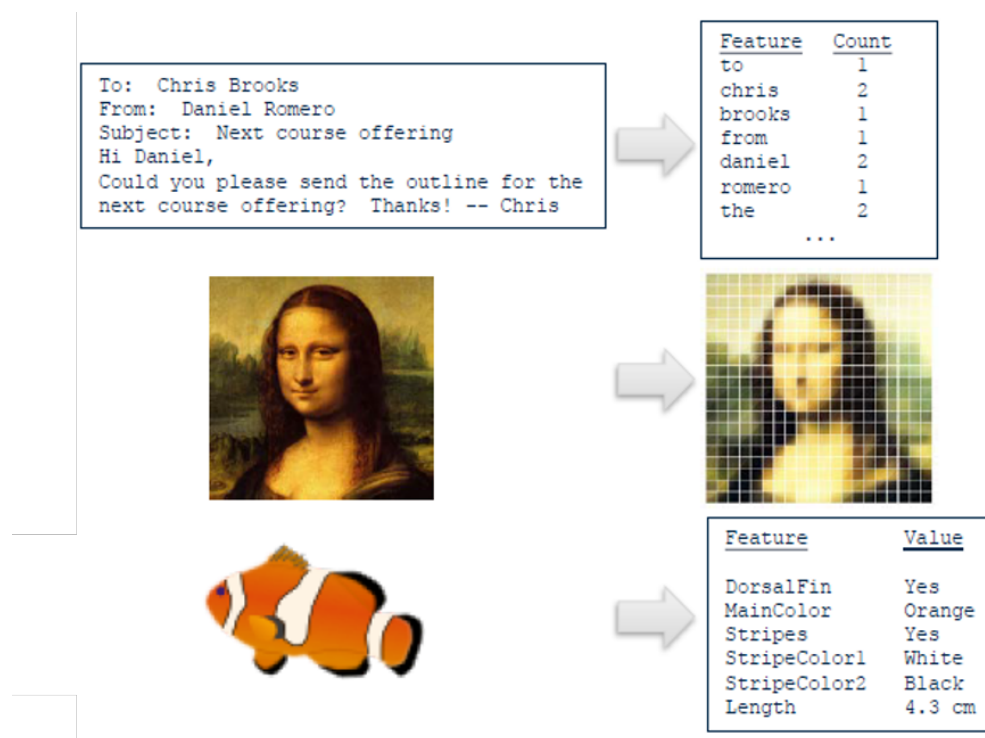


Figura 2.1: Ejemplos de información que se pueden usar como información para un algoritmo

Para poder procesar esta información, en la cual no es posible llegar a una salida con métodos tradicionales de decisiones binarias existe *machine learning*, una intersección de diferentes campos entre los que se encuentran la estadística y la inteligencia artificial que tiene como objetivo el desarrollo de procedimientos y técnicas basadas en operaciones lógicas para extraer información de un conjunto de datos. [19]

*Machine learning* es una de las mejores alternativas para realizar algoritmos donde la información cuenta con una estructura compleja. Esto lo logra ya que le es posible imitar los procesos de pensamiento y aprendizaje de un ser humano, donde la información recibida puede ser llamada experiencia. Se dice entonces que es capaz de aprender y realizar toma de decisiones en eventos futuros sobre los que tenga conocimiento.

En la Figura 2.2 se resumen los pasos más importantes para un plantear un proceso de *machine learning* de manera general, en primer lugar se necesita elegir una representación de nuestra información como se mostró en la Figura 2.1, posteriormente se elige de que forma evaluaremos el desempeño de nuestros algoritmos para finalmente llegar a un proceso de optimización donde, si es necesario, se realiza una sintonización de parámetros del algoritmo.



Figura 2.2: Diagrama de flujo del proceso general de *machine learning*

La mayor ventaja se se puede obtener de estos procesos de aprendizaje es que no se necesita tener un conocimiento completo de la estructura de la información para poder aplicar un algoritmo, solamente se necesita comprender que tipo de entrada se tiene y que tipo de salida se desea obtener. Esto último porque existen principalmente dos categorías de algoritmos:

- Aprendizaje supervisado: Se utiliza para tareas de regresión y clasificación.
- Aprendizaje no supervisado: Se utiliza para tareas de reducción dimensional y agrupación.

Los modelos generados por estos algoritmos, ya sea de los supervisados o de los no supervisados, deben ser capaces de predecir o describir características de los datos debido a que

se basan principalmente en estadística y en la creencia de que existe un modelo que pueda explicar de mejor forma la información que estamos observando.

Es importante señalar que el algoritmo, al generar el modelo matemático que resuelve el problema, puede presentar dos problemas principalmente. El primero de ellos es conocido como subentrenamiento, en este estado se puede asegurar que no fue posible realizar una aproximación correcta y la estructura de los datos no fue encontrada correctamente. Esto se puede observar en el ejemplo mostrado en la Figura 2.3, donde se compara un modelo mal ajustado a la izquierda contra un modelo mejor ajustado en la derecha, suponiendo un problema de tamaño contra el precio de venta de una casa contra el tamaño de la construcción.




Figura 2.3: Subentrenamiento vs Modelo correctamente ajustado

En el caso contrario se tiene el sobreentrenamiento, donde el algoritmo intenta ajustarse de la mejor forma para encontrar la estructura matemática de los datos, lo que al igual que el subentrenamiento provocará que los nuevos datos que vayan a ser evaluados con el programa no puedan ser clasificados o predichos de manera adecuada.




Figura 2.4: Modelo correctamente ajustado vs Sobreentrenamiento

## 2.2. Aprendizaje supervisado

Este tipo de aprendizaje de *machine learning* se distingue por contar información previamente clasificada con la salida deseada para cada dato, en otras palabras para cada entrada  $X$  existe una salida  $Y$  con la que se encuentra relacionada de tal forma que  $Y$  es la etiqueta que clasifica correctamente este dato [19, 21].

Como ejemplo se puede tomar lo mostrado en la Figura 2.5, en ella vemos que existen dos clases de datos, las cruces y los círculos. En este ejemplo se asume que la información en la computadora ha sido correctamente introducida por el usuario y el algoritmo conocerá de manera previa la respuesta para cada dato. Ahora el algoritmo lo que buscará será una forma de poder separar y crear regiones donde sea más probable que sea una respuesta diferenciada, en este caso a la derecha de la línea azul serán cruces y a la izquierda círculos.




Figura 2.5: Ejemplo de la aplicación de un algoritmo de aprendizaje supervisado

Este tipo de enfoque para resolución de problemas plantea al investigador la condición de que debe conocer que es lo que desea obtener como salida, ya que la información es presentada en una sola exhibición, lo que provoca que si se consigue aun más información en un futuro cercano, será necesario un reentrenamiento del algoritmo. [23]

Clasificar la información que se utilizará en el algoritmo puede resultar complicado, uno de los problemas más grandes es que el investigador no cuente con los conocimientos necesarios para distinguir entre clases. Otro puede ser que el investigador no haya sido quien haya creado la base de datos lo que en ocasiones provoca que haya datos incorrectos, no solo en la etiqueta, además de que es posible que los campos puedan estar vacíos por alguna

equivocación. Es recomendable que siempre que se desea emprender un proyecto utilizando *machine learning*, en caso de no tener el conocimiento, se consiga la asesoría necesaria para realizar un diagnóstico a la base de datos.

Entre los algoritmos que se encuentran en esta categoría los más conocidos son:

- Regresión lineal
- Support Vector Machine
- Árboles de decisión
- Vecinos cercanos
- Redes neuronales

### 2.3. Support Vector Machine

El Support Vector Machine (SVM) es uno de los modelos de aprendizaje más populares actualmente, esto se debe a que es uno de los algoritmos más poderosos y versátiles, adicionalmente es uno de los más fáciles de interpretar ya que sus resultados son bastante claros. Es capaz de realizar clasificaciones con datos que son linealmente separables así como los que no lo son. [21]

El algoritmo utiliza un principio discriminante que Vapnik describe en [24], de tal forma que los vectores de información de entrada se mapean a una dimensión mayor, con el objetivo de encontrar hiperplanos que hagan divisiones entre las diferentes clases que se esperan como salida del algoritmo. Lo más importante es que el algoritmo no busca encontrar la estructura completa de los datos sino que busca hacer una generalización de la localización de los límites de las clases, lo que reduce el riesgo de sobreentrenamiento.

En la Figura 2.6 se puede ver un ejemplo de cómo funciona, se crea un vector que funcione como frontera y permita hacer una separación clara entre las clases negro y amarillo. De esta forma los vectores de soporte, que ayudan a formar el rectángulo verde, muestran que existe el mayor margen posible entre ambos grupos.






Figura 2.6: Ejemplo de la gráfica producida por un algoritmo de SVM

El paso más importante en este algoritmo es encontrar el o los hiperplanos óptimos que dividan eficientemente las clases, es importante resaltar que los valores de los datos que sean introducidos como entrada, serán los coeficientes de un polinomio que lo describirá. Veamos lo que sucede en el caso de una separación de dos clases que utilizaran las etiquetas  $+1$  y  $-1$ . El ejemplo será  $X = \{x^t, r^t\}$ , donde deseamos encontrar un vector  $w$  y un escalar  $b$  para cada pareja  $(y_i, x_i)$ , donde  $y_i \in \{-1, 1\}$ , tal que:

$$\begin{aligned} w \cdot x_i + b &\geq 1 && \text{para } y_i = 1 \\ w \cdot x_i + b &\leq -1 && \text{para } y_i = -1 \end{aligned} \quad (1)$$

El hiperplano óptimo será aquel que divida a ambas clases con el mayor margen entre ellas y se define como:

$$w_0 \cdot x_i + b_0 = 0 \quad (2)$$

para ayudar en la tarea de clasificación, existen dos hiperplanos paralelos al óptimo donde  $w_0 \cdot x_i + b_0 = 1$  y  $w_0 \cdot x_i + b_0 = -1$ , a la región creada entre estos se le conoce como margen. Se considerará como adecuado el algoritmo cuando la distancia entre ellos sea máxima, lo que geométricamente se define como [24]:

$$\frac{2}{\|w\|} \quad (3)$$

La tarea del SVM se puede resumir, como se menciona en [24]:

Minimizar  $\|w\|$  que se encuentra limitado por  $y_i(w \cdot x_i - b) \geq 1$  para  $i = 1, \dots, n$

por lo que la  $w$  y la  $b$  que resuelven nuestro problema determinan el clasificador como  $f(x, w, b) = \text{sign}(w_i \cdot x_i + b)$ .

## 2.4. Random Forest

El Random Forest (RF) tiene una diferencia con respecto al método anterior, no es un sólo algoritmo el que se aplica. El RF es lo que se conoce como un método de ensamble, debido a que en un sólo momento se aplican varios algoritmos que pueden ser diferentes i iguales. En el caso específico del RF se usa el Árbol de decisiones varias veces, pueden ser 10, 100 o 1000, esto queda a criterio del programador. Para que el algoritmo sea más efectivo la base de datos para entrenarlo debe separarse de forma aleatoria tantas veces como árboles se tengan. [21]

El árbol de decisiones es uno de los algoritmos más utilizados para tareas de clasificación. En pocas palabras el resultado se produce a través una serie de preguntas del tipo si/no que se generan con jerarquía para obtener respuestas o decisiones. Una de sus mayores ventajas es que puede ajustarse a bases de datos que contentan una estructura compleja para encontrar las divisiones entre las diferentes clases.

Cómo puede verse en el ejemplo en la Figura 2.7 jerarquía de las preguntas se produce utilizando las características de la planta, cómo la longitud del pétalo, agrupando en diferentes nodos aquellas que cuentan con características similares según la regla de decisión. Para crear la jerarquía es necesario conocer que tan bien se ha realizado la división de los datos, por lo que es necesario medir la impureza de cada nodo. Los nodos se consideran puros cuando solo existen datos de una sola clase, una estrategia común es medir la entropía del sistema utilizando la siguiente ecuación [25]:

$$I_m = - \sum_{i=1}^k p_m^i \log p_m^i \quad (4)$$

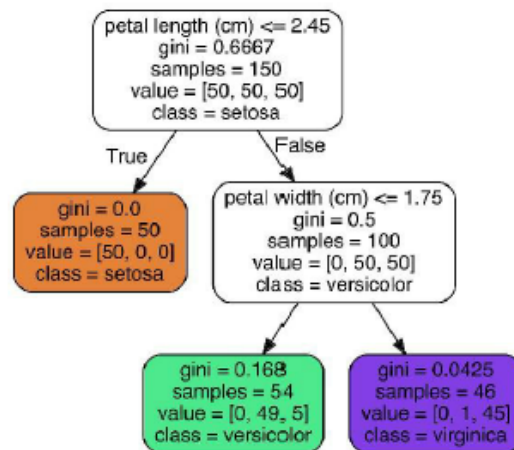


Figura 2.7: Árbol de decisiones para un problema de clasificación de diferentes especies de la flor Iris

Una de las mayores desventajas del árbol de decisión es su tendencia hacia el sobreentrenamiento, lo que produce resultados insatisfactorios. Sin embargo, el RF aprovecha el efecto producido por el *Bagging*, esto es que aunque un solo árbol pueda sobreentrenarse, el promedio de un gran número de estos lo evita mejorando su desempeño. [21]

La Figura 2.8 muestra un ejemplo de la representación gráfica de un algoritmo de FR, en esta se puede apreciar que las fronteras de decisión, a la derecha, no se encuentran plenamente definidas. Esto se debe a que muestra el promedio de las decisiones hechas por los diferentes árboles que se hayan utilizado y representa la probabilidad de que un dato que se encuentre en esa zona pertenece a una u otra clase.




Figura 2.8: Ejemplo de regiones de decisión generadas por un algoritmo de RF.

## 2.5. Redes Neuronales

El algoritmo de Redes Neuronales (ANN) fue desarrollado a partir de la idea de imitar los procesos biológicos de aprendizaje. Este método es del tipo no paramétrico, por lo que no es necesario aplicar una reducción dimensional como en el caso del SVM. Permite representar funciones complejas no lineales para realizar decisiones utilizando una combinación de pequeñas unidades lineales llamadas neuronas. [22]

Es importante resaltar que estas redes no buscan entender el proceso de funcionamiento del cerebro, sino el construir un método útil para realizar el aprendizaje utilizando información. En la Figura 2.9 se ve un ejemplo como se interconectan las neuronas en las capas intermedias, llamadas ocultas, para obtener una salida.




Figura 2.9: Estructura básica de una red neuronal

El elemento más básico de procesamiento en las redes neuronales se llama *perceptrón*, este es un elemento lineal que dado unos pesos o coeficientes  $w$  para cada entrada  $x$  se calcula una salida  $y$  [19]. En la Figura 2.10 se observa la distribución de las entradas  $x$  con su respectivo peso, al realizar la suma ponderada se introduce en una función no lineal la que dará la salida  $y$  como resultado. Las funciones de activación más utilizadas son:

- Rectificador

También conocida como función rampa, muy utilizada en redes neuronales convolucionales debido a que genera menor error que la sigmoide, su salida esta en el rango entre 0 e  $\infty$ . [26]

$$y = \max(0, x) \quad (5)$$

- Tangente hiperbólica

Se utiliza para predecir la probabilidad de una salida, sin embargo es de lenta convergencia, su salida esta en el rango entre -1 y 1.

$$y = \tanh(x) \quad (6)$$

- Sigmoide

Similar a la anterior pero menos amplia, da una respuesta en el rango entre 0 y 1.

$$y = \frac{1}{1 + e^{-x}} \quad (7)$$




Figura 2.10: Estructura básica de un perceptrón

En esta Tesis la información de entrada serán imágenes, por lo que se necesita extraer características de la imagen y codificarlas para formar un vector de información, se utilizaron tres elementos para describir cada una de las imágenes de la base de datos:

- Momentos de Hu

Los momentos en las imágenes son promedios ponderados de la intensidad de píxeles que se puede utilizar para encontrar algunas características como bordes o texturas. Hu propuso en [27] una serie de momentos que tienen como característica ser invariantes a la rotación y a la escala. Hu calcula 7 momentos invariantes utilizando los momentos geométricos definidos por la siguiente ecuación:

$$\mu_{pq} = \iint (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy \quad (8)$$

Donde  $\mu_{pq}$  es el momento geométrico de orden  $(p + q)$ ,  $f(x, y)$  es el valor del píxel en la posición  $(x, y)$  de la imagen y  $(\bar{x}, \bar{y})$  es el centroide de la misma.

- **Histograma**

Los histogramas son gráficas en donde se puede obtener una idea general de como se encuentra distribuida la intensidad en una imagen. Utilizando la imagen en escala de grises se pueden contar cuantos son los píxeles que le pertenecen a cada uno de los valores de la escala, de 0 a 255, y de esta forma elaborar una descripción de la misma. Con los histogramas se puede encontrar de manera intuitiva el contraste, el brillo o la intensidad de luz dentro de la imagen.

- *Haralick features*

En [28] se emplea un método para la extracción de características en imágenes en escala de grises, específicamente la textura. Aunque para el ser humano se puede considerar como una una tarea sencilla, no lo es así para los *software*, para que sea capaz de interpretar la imagen se obtiene la matriz de coocurrencia descrita por  $G$ , donde  $N_g$  es el número de niveles de gris presentes en la imagen.

$$G = \begin{bmatrix} p(1, 1) & p(1, 2) & \cdots & p(1, N_g) \\ p(2, 1) & p(2, 2) & \cdots & p(2, N_g) \\ \vdots & \vdots & \ddots & \vdots \\ p(N_g, 1) & p(N_g, 2) & \cdots & p(N_g, N_g) \end{bmatrix} \quad (9)$$

Las características de textura son aplicables de manera general a cualquier tipo de imagen, y estan basadas en estadísticas que resumen la distribución de la frecuencia relativa de aparición de los diferentes tonos de gris. Las 14 características que se obtienen son : *Angular Second Moment, Contrast, Correlation, Sum of Squares: Variance, Inverse Difference Moment, Sum Average, Sum Entropy, Entropy, Difference Variance,*

*Difference Entropy, Information Measures of Correlation, Maximal Correlation Coefficient.*

## 2.6. Aprendizaje no supervisado

Este tipo de aprendizaje, a diferencia del tipo supervisado, prescinde de las etiquetas que clasifican la información. El objetivo los métodos que se encuentran en esta categoría es el encontrar relaciones entre los grupos de datos que potencialmente existen dentro de la base, sin la necesidad de tener un maestro.

En el ejemplo que se muestra en la Figura 2.11 se aprecia como es que existen dos grupos de datos, de los cuales no se conoce su etiqueta, como tienen valores de  $X_1$  y  $X_2$  similares se puede suponer que representan datos de clases parecidas, esto es un ejemplo de los algoritmos de agrupamiento o *clustering*. Entre los más utilizados se encuentran:

- k-Medias
- Análisis de agrupamiento jerárquico




Figura 2.11: Ejemplo de la aplicación de agrupamiento

Por otro lado existe un segundo tipo de algoritmos de aprendizaje no supervisado dedicados a la reducción dimensional. La mayoría de los algoritmos asumen que los datos de entradas serán un vector que representa los coeficientes de un polinomio, afortunadamente en una gran

mayoría de los problemas del mundo real es posible reducir estos coeficientes o características a un número más manejable. [21]

Se debe recalcar que este tipo de algoritmos existen para cuando el investigador desea estudiar el comportamiento de los datos más que obtener un resultado propiamente. Así mismo los algoritmos que se utilizan para la reducción dimensional, se utilizan para una etapa de preprocesamiento y que el análisis con algoritmos de aprendizaje supervisado sea más rápido. [20]

## 2.7. Principal Component Analysis

Este algoritmo forma parte de los que se encuentran destinados a la reducción dimensional. Principal Component Analysis (PCA) permite encontrar una proyección de la información en un espacio dimensional menor eliminando las dimensiones menos significativas. Este método se puede emplear para explorar y visualizar las relaciones con las que cuentan los datos, de tal forma que al proceder con la eliminación se pierda la menor cantidad de información posible. [19]

En este método lo más importante es encontrar una transformación donde en los datos no exista una correlación directa, de esta forma se podrá encontrar la varianza con valor máximo en cada una de las dimensiones, lo que se conoce como componente [20]. El proceso más utilizado para realizar el PCA es por medio de la descomposición de valores singulares (SVD), [29] con este proceso se encuentran los valores propios o eigenvalores de una matriz haciendo una factorización compleja, al conocer los valores singulares es posible encontrar cuántos componentes logran capturar la mayor cantidad de la información, a estos se les da el nombre de principales.

El uso del SVD también es posible utilizarlo para la reducción de información que necesitan procesar los algoritmos de aprendizaje supervisado, un preprocesamiento. La factorización se realiza tal que:

$$X = USV^T \tag{10}$$



donde  $S$  es una matriz diagonal positiva que contiene los valores singulares de  $X$ .  $U \in \mathbb{R}^{n \times p}$  es una matriz ortogonal conocida como los valores singulares izquierdos.  $V \in \mathbb{R}^{p \times p}$  es otra matriz ortogonal, esta están contenidos los vectores singulares. El eigenvalor correspondiente a cada eigenvector determina la contribución de ese componente principal en la variación de la información. En la Figura 2.12 se puede apreciar un ejemplo del proceso que se aplica al utilizar PCA, en primer lugar se buscan los componentes principales donde hay más varianza, en este caso hay 2 dimensiones por lo tanto hay 2 componentes. Después se busca la rotación adecuada donde se elimina la relación que tienen, se elimina el componente menos significativo y finalmente se muestran los datos en su distribución original utilizando únicamente uno de los componentes principales




Figura 2.12: Transformaciones al aplicar PCA

## 2.8. Evaluación de métodos

Al utilizar algoritmos de *machine learning* es importante que se tenga la posibilidad de conocer el desempeño de este para determinar si es adecuado o en caso contrario afinar afinar

los parámetros, por ejemplo en el Random Forest el número de árboles. Para los algoritmos de clasificación existen diferentes métodos para realizar esta medición, a continuación se enlistarán y describirán las más utilizadas.

- Matriz de confusión

La matriz de confusión es una herramienta que permite la visualización del desempeño de un algoritmo, es empleada cuando se tienen problemas de clasificación ya que en esta se muestra un resumen de cómo fue clasificada la información que se utilizó para probar el algoritmo ya entrenado. Lo normal es hacer una división de toda la información recopilada en una relación 70-30, donde la mayor parte se utiliza para entrenar. En la Tabla 2.1 se ve cómo se clasifica para un ejemplo de dos clases, sin embargo en caso de tener más clases la matriz aumentará su tamaño, si son 3 clases será una matriz de 3x3.

	Clase predicha		
Clase Verdadera	Positivo	Negativo	Total
Positivo	tp: verdadero positivo	fn: falso negativo	$p$
Negativo	fp: falso positivo	tn: verdadero negativo	$n$
Total	$p'$	$n'$	$N$

Tabla 2.1: Matriz de confusión para dos clases.

- Precisión

Se puede definir como la proporción en que se clasifica correctamente los ejemplos que se marcaron como positivos con respecto del número total de ejemplos que fueron correctamente clasificados como positivos o negativos.

$$Precision = \frac{tp}{p} \quad (11)$$

- Exhaustividad

En este se puede observar la proporción de ejemplos marcados de manera correcta como positivos con respecto a todos los que se hayan clasificado como positivos, falsos y verdaderos.

$$Recall = \frac{tp}{p'} \quad (12)$$

- Valor-F

Este enfoque para realizar la medición busca la media armónica entre la precisión y la exhaustividad.

$$F_1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (13)$$

## 2.9. Imágenes hiperespectrales

Durante las últimas décadas el interés por el procesamiento de imágenes se incrementó, esto se debe a dos razones principales, en primer lugar la mejora en los sistemas de adquisición y en segundo lugar la capacidad de almacenamiento y cómputo de los equipos. Existen diferentes tipos de sensores para la adquisición de imágenes y estos a su vez producen imágenes con diferentes propiedades, esta Tesis hará énfasis en las que se conocen como hiperespectrales. [30]

Las imágenes hiperespectrales, o *HSI* por su denominación en inglés, son el resultado del uso de tecnología de espectroscopia y de adquisición de imágenes [31]. En este proceso se realiza una fotografía de un objeto y se obtiene la reflectancia de la luz en diferentes longitudes de onda del espectro electromagnético.

El ojo humano, en comparación con los modernos sensores que se utilizan para la adquisición de fotografías, no es capaz de distinguir los diferentes espectros, por lo que solamente la reflectancia de la luz que incide en los objetos permite identificar colores primarios y sus combinaciones, en cambio al utilizar los diferentes sensores es posible detectar lo que hay más allá, como el espectro infrarrojo o el ultravioleta, en la Figura 2.13 Se puede apreciar las diferentes partes del espectro electromagnético, de 400 nm a 700 nm es lo que se conoce como espectro visible, siendo posible verlo con el ojo. [32]

Existen diferentes sensores para adquirir imágenes espectrales, una forma para clasificarlos

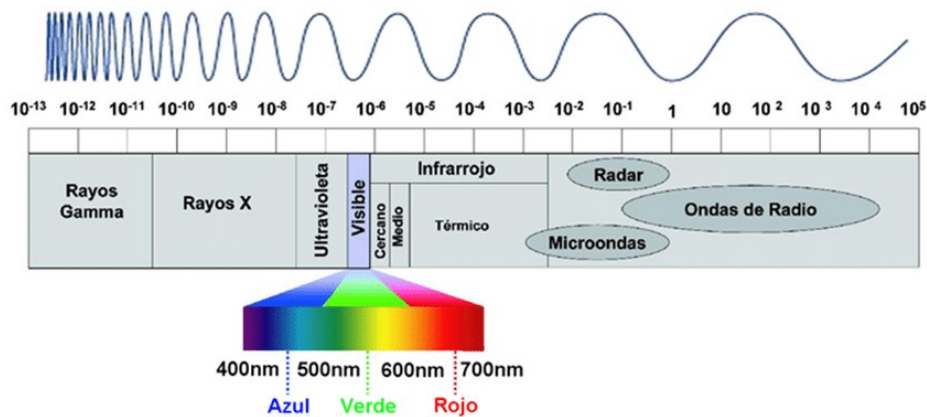


Figura 2.13: Espectro electromagnético, la longitud de onda ( $\lambda$ ) en metros [37]

es el número de divisiones en las que parte el espectro electromagnético, a estas se les llama bandas espectrales y pueden ser amplias o estrechas. Hay dos grandes clasificaciones [36]:

- Multiespectrales: Si tiene hasta 10 bandas.
- Hiperespectrales: Si tiene 100 o más bandas.

Los sensores que tienen la capacidad para adquirir las diferentes mediciones espectrales, recopilan la información obtenida como un conjunto de fotografías, los datos se almacenan en una estructura tridimensional, con dos dimensiones espaciales y una dimensión espectral ( $x, y, \lambda$ ), denominada hipercubo, la composición de uno general se muestra en la Figura 2.14. Los diferentes métodos que existen para la adquisición de fotografías, se encuentran en la Figura 2.15, en el inciso a tres diferentes técnicas que pueden ser multiespectrales o hiperespectrales, esto depende de la cantidad de bandas, estas son:

- Escaneo de punto

En este tipo de fotografía se hace la toma de imágenes en un solo punto del objeto, sin embargo se pueden obtener la información de diferentes anchos de banda, similar al uso de espectrofotómetro.

- Escaneo de línea




Figura 2.14: Estructura de un hipercubo

Este tipo de escaneo requiere de movimiento a través del objeto que se desea estudiar, en una sola imagen se adquiere la información de diferentes anchos de banda, para utilizar los datos es necesario un proceso de *stitching*, un procedimiento donde se utilizan múltiples imágenes para la obtención de una imagen panorámica.

- Escaneo de ancho de banda

Estas fotografías adquieren la información en anchos de banda específicos previamente seleccionados.

En el inciso b de la Figura 2.15 se muestra una técnica de adquisición denominada mosaico. En esta técnica es posible adquirir una fotografía del objeto y la información de las diferentes bandas espectrales en un solo momento para la formación del hipercubo, la única desventaja con este método es que la cantidad de bandas que se puede adquirir no supera el límite de las multiespectrales.

## 2.10. Índices de vegetación

Para obtener información útil de las imágenes hiperespectrales es necesario someterlas a algún procesamiento por computadora. En el caso de los problemas relacionados a plantas

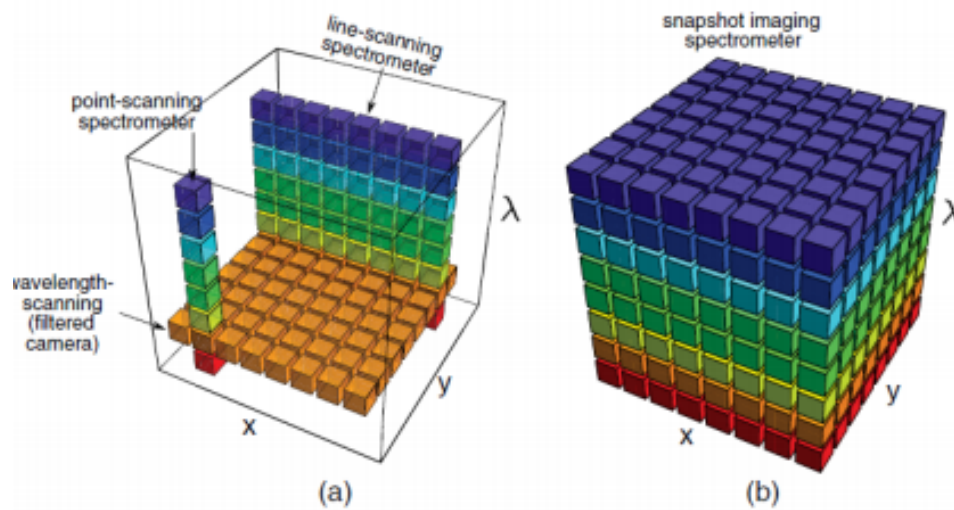


Figura 2.15: Técnicas de adquisición de fotografías espectrales

existen los llamados Índices de Vegetación. Estos combinan información de diferentes bandas espectrales para incrementar la respuesta a la luz solar.

En particular, la mayoría de los índices de vegetación se emplean la banda de rojo (RED) y la del infrarrojo cercano (NIR), debido a que han presentado buena respuesta para el análisis espacial y temporal de la actividad fotosintética así como las variaciones estructurales de las plantas, esto se debe a que a mayor cantidad de clorofila existe una mayor absorción de la luz roja y una reflectancia mayor en el infrarrojo cercano.[33]

Para obtener la información de los índices de vegetación es necesario aplicar una transformación matemática y de esta forma acentuar las propiedades espectrales de las plantas así como generar diferencias con otros elementos de la imagen, cómo puede ser el suelo por ejemplo, lo que permite elaborar análisis cualitativos para determinar el estado de la vegetación [34]. A continuación se enlistan los índices que serán utilizados en esta Tesis.

- Índice de vegetación normalizada (NDVI)

El Índice de vegetación normalizada, o por sus siglas en inglés NDVI, es el índice más utilizado para estudios en plantas. Este se encuentra directamente relacionado con la capacidad fotosintética y de absorción de luz, sus valores se encuentran entre -1 y 1 y los píxeles que cuentan con mayor acumulación de clorofila serán los que obtengan un

valor entre 0.3 y 0.8 [35]. Este índice se calcula de acuerdo a la siguiente fórmula :

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (14)$$

donde NIR es la medición más aproximada a los 800 nm y RED es la que se encuentra lo más próxima a 680 nm.

- Índice renormalizado de vegetación (RDVI)

Este índice es una modificación del NDVI, su mayor diferencia es que se trata de una combinación entre el NDVI y un índice llamado DVI, de esta forma se reduce las variaciones en las mediciones que pueden provocar diferentes iluminaciones [38]. Su valor al igual que NDVI va de -1 a 1 y se calcula según la siguiente fórmula:

$$RDVI = \frac{NIR - RED}{\sqrt{NIR - RED}} \quad (15)$$

donde NIR es la medición más aproximada a los 800 nm y RED es la que se encuentra lo más próxima a 680 nm.

- Índice de vegetación normalizado de banda estrecha roja (NDVI705)

Ligera modificación del NDVI, en esta se hace un uso de bandas más estrechas únicamente en el espacio del infrarrojo cercano. La mayor ventaja sobre el NDVI es que es menos propicio a saturarse cuando se realiza la medición. Sus valores van de -1 a 1 y la vegetación se encuentra entre 0.2 y 0.9 [39]. Se calcula utilizando la fórmula:

$$NDVI705 = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}} \quad (16)$$

donde  $\rho_{750}$  se refiere a la medición más próxima a los 750 nm y  $\rho_{705}$  a los 705 nm.

- Índice de vegetación mejorado (EVI)

Este índice fue desarrollado como una alternativa del NDVI debido a algunas limitaciones que tiene, entre ellas la saturación que se da en casos donde hay más concentración

de clorofila así como la reducción de la influencia de factores externos como la luz. Este índice es más sensible que NDVI, sus valores son entre 0 y 1 [40]. La fórmula que a continuación se presenta:

$$EVI2 = 2.4 \frac{NIR - RED}{NIR + RED + 1} \quad (17)$$

donde NIR puede ser cualquier banda entre los 780 y los 1400 nm, y RED puede ser cualquier banda entre 640 y 760 nm, no es la original, esta fue desarrollada en caso de que el sensor que se utilice carezca de la posibilidad de medir bandas azules, además es importante resaltar que la banda azul es propensa al ruido [41].

- Índice de Diferencia normalizada en el *red edge*

Descrito en [42] emplea las bandas de 712 nm y 680 nm ya que en estas bandas es posible detectar cuando una planta se encuentra sometida a algún estrés, originalmente se utilizó para describir la condición de salud de los cultivos, y al igual que el NDVI se encuentra normalizado entre -1 y 1, se utiliza la siguiente fórmula:

$$NDVI_{rededge} = \frac{\rho_{712} - \rho_{680}}{\rho_{712} + \rho_{680}} \quad (18)$$



# Capítulo 3

## Metodología

En esta sección se mostrará la estructura de la metodología que se elaboró basado en experimentos previos, así como se describirán a detalle los pasos más importantes durante la realización del experimento planteado, entre ellos los componentes del banco de pruebas que se adaptó para la obtención de imágenes hiperespectrales.

El modo de trabajo del banco de pruebas en gran parte se debe a la elección de la cámara hiperespectral, su particular modo de captura de imágenes hizo que fuera necesario el desarrollo de un pequeño banco de pruebas motorizado así como la adaptación de iluminación para simular la luz del Sol y obtener una reflectancia de todos los espectros que puede capturar la cámara.

La existencia de los índices de vegetación es lo que permite hacer el análisis de las imágenes, en estos lo principal que se busca es la existencia de clorofila, esta determina en gran parte el estado del desarrollo de las plantas, adicionalmente en las bandas roja e infrarroja es posible ver estados deteriorados de la hoja, los índices permiten establecer la relación que existe para establecer categorías de daño y que sea analizado por medio de algoritmos.

La selección de los algoritmos de *machine learning* se hizo después de una revisión de la literatura a profundidad. Se analizó que no todos los algoritmos presentan condiciones favorables para aplicarse, los que se seleccionaron se hizo pensando en que la cantidad de información para procesar podría ser limitada, por ejemplo el *Support Vector Machine* es recomendado para cuando se tiene una cantidad pequeña de muestras.

### 3.1. Diagrama de flujo de la metodología

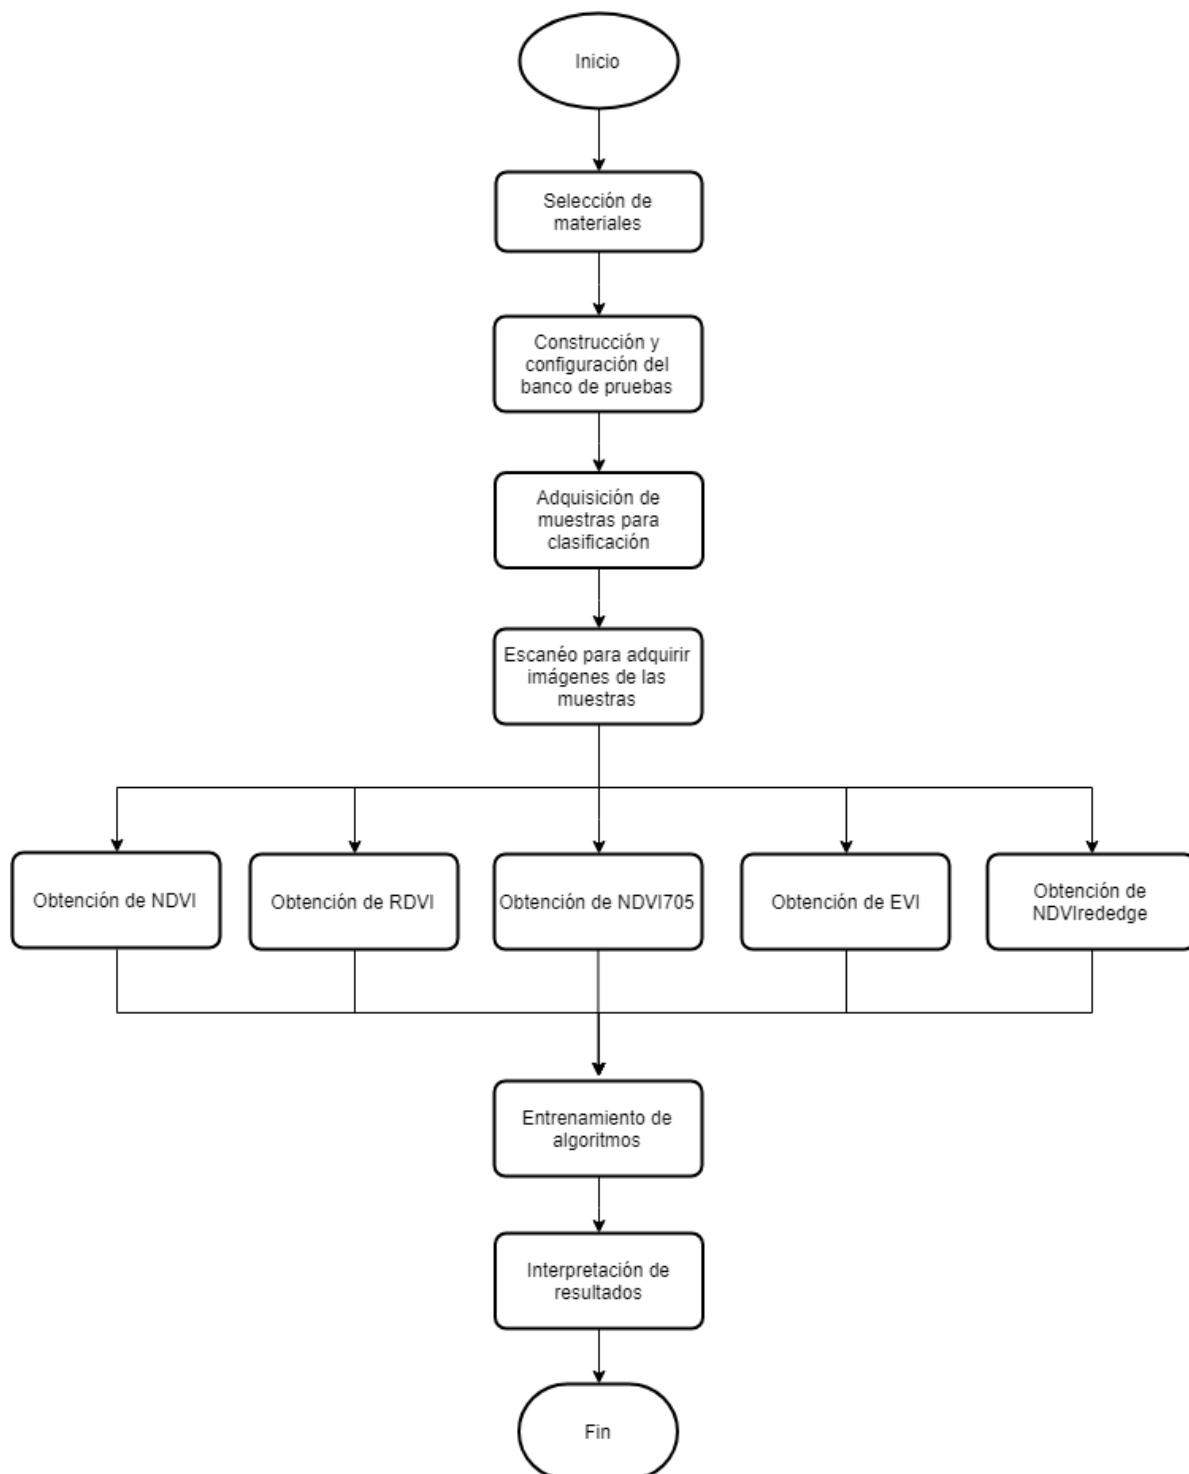


Figura 3.1: Diagrama de flujo de la metodología seguida

## 3.2. Selección de la cámara

Como se ha mencionado, existe una clasificación para las cámaras según el número de bandas espectrales que puede adquirir, como se desea hacer un análisis de mayor detalle lo ideal es una cámara hiperespectral. La cámara seleccionada para este experimento fue el modelo MQ022HG-IM-LS100-NIR de la marca XIMEA, esta se puede ver en la Figura 3.2, entre sus mayores ventajas se encuentra la interfaz de comunicación es por medio de USB 3.0, así como sus dimensiones midiendo 26x26x31 mm y pesando 32g.



Figura 3.2: Cámara MQ022HG-IM-LS100-NIR

Esta cámara implementa el uso del sensor CMV2000 manufacturado por la compañía IMEC, es un sensor de tipo *pushbroom* lo que significa que es necesario que exista un movimiento para la adquisición de imágenes. Como se puede ver en la Figura 3.3, las bandas se encuentran distribuidas de manera lineal, los colores representan de manera aproximada como se distribuyen los espectros.




Figura 3.3: Sensor CMV2000

Este sensor implementa filtros basados en el interferómetro de Fabry-Pérot lo que permite virtualmente integrar cientos de espectrómetros en un solo sensor, el interferómetro como se

observa en la Figura 3.4, se compone de dos superficies altamente reflejantes separadas por una distancia  $L$  para formar un resonador descrito por la siguiente ecuación, donde  $\Theta$  es el ángulo de incidencia de la luz:

$$k\lambda = 2nL \cos \Theta \tag{19}$$




Figura 3.4: Interferómetro de Fabry-Pérot

Como se menciona anteriormente, esta cámara necesita movimiento para poder realizar la adquisición de imágenes. Como se aprecia en la Figura 3.5 las bandas se encuentran distribuidas a lo largo de los 1088 píxeles de la imagen, sin embargo la cámara de este experimento se encuentra filtrada para solo adquirir las que se encuentran entre los 600 y los 970 nm.

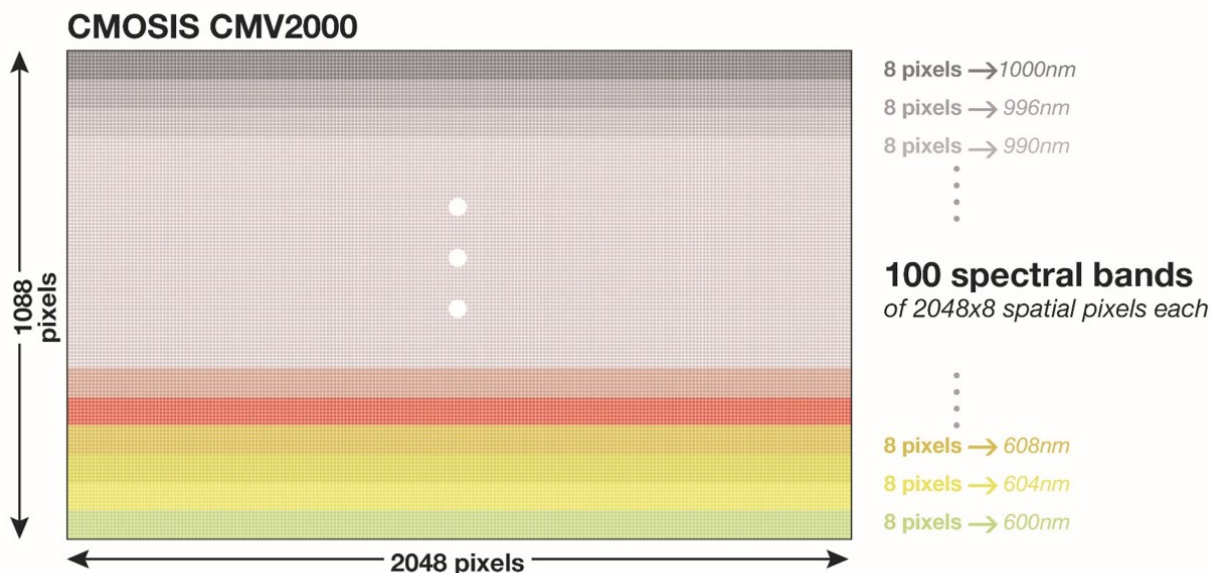


Figura 3.5: Distribución de las bandas espectrales en la cámara MQ022HG-LS100-NIR

En la Figura 3.5 se observa que las bandas tienen una resolución de 2048x8 píxeles y cada

banda espectral esta separada de la siguiente por 4 nm, en el modelo de cámara que se utiliza en esta Tesis se pueden adquirir 100+ bandas. Esto quiere decir que se obtienen por lo menos 100 bandas desde los 600 nm, aunque existen algunas bandas que no pueden ser utilizada por el usuario ya que son para desarrollo del productos del fabricante.

La cámara se utiliza en conjunto con el lente #67-716 de Edmund Optics, el cual se encuentra recomendado para aplicaciones de visión por computadora donde se vaya a utilizar luz infrarroja así como sensores de 2/3" cómo el de la cámara. En la Tabla 3.1 se enlistan las características más importantes.



Figura 3.6: Lente #67-716 de Edmund Optics

Distancia Focal	35 mm
Apertura	f/1.65-f/22
<i>Field of View</i>	14.3°
<i>Instant Field Of View</i>	0.072
Distancia de trabajo	165-∞ mm

Tabla 3.1: Características del lente #67-716 de Edmund Optics

### 3.3. Consolidación del banco de pruebas

Para elegir un banco de pruebas apropiado se tomó en consideración la cámara hiperespectral, como se ha mencionado se requiere que exista movimiento a lo largo de un eje para la adquisición de imágenes. A continuación se describirán los elementos que forman la estructura y los que permiten que la cámara sea capaz de realizar el escaneo en las muestras.

Dadas las condiciones de la cámara, la cual utiliza la técnica de *linescan*, para el banco de pruebas se hizo la adaptación de un proyecto existente para la construcción de una mesa

cartesiana. De esta manera es posible asegurar el movimiento a lo largo de un eje de manera controlada.

La estructura de la mesa cartesiana esta hecha de perfil de aluminio, en la zona de prueba hay una placa de aluminio donde se colocan otros elementos. En la Figura 3.7 se puede apreciar la composición de la estructura y la ubicación de algunos elementos, entre los que se incluyen:

- 1 motor a pasos NEMA34, 1.8 ° por pulso
- 1 guía lineal ZLW-1660

El driver utilizado para controlar el motor fue ST-M5045 configurado a tener 128,000 pasos por cada revolución, los pulsos para el control de la conmutación de las bobinas del motor se envían utilizando un microcontrolador ATMEGA328P el cual recibe la instrucción de arranque desde la computadora del sistema. Todo el sistema se encuentra alimentado por una fuente de 24V CD.




Figura 3.7: Banco de pruebas basado en una mesa cartesiana

Para la adquisición de imágenes utilizando la cámara se hizo el diseño de un soporte de 2 piezas, que se pueden ver en la Figura 3.8. Su manufactura fue en impresión 3D utilizando filamento de ABS, su diseño permite ajustar la altura a la que se encontrará la cámara y aumentar el campo de visión.




Figura 3.8: Piezas del soporte diseñado para sostener la cámara

Se implementó iluminación para que en la adquisición de fotografías se obtuviera la reflectancia de los espectros rojo e infrarrojo, por lo que se eligieron lámparas de halógeno debido a que estas son capaces de emitir luz que ocupa todo el espectro electromagnético incluso en el infrarrojo cercano. Como se aprecia en la Figura 3.9, se dispusieron 2 lámparas de manera perpendicular al movimiento.




Figura 3.9: Prueba de iluminación

Al adquirir imágenes de la cámara, incluso con la iluminación adecuada, el sensor presenta una serie de errores por manufactura que deben ser corregidos de manera manual. En la Figura 3.10 se puede observar que la imagen tomada no tiene la suficiente claridad y esto

provoca errores en los cálculos de índices de vegetación.




Figura 3.10: Imagen RAW sin corrección de la cámara

Para resolver este problema se hace uso de una corrección llamada *Flat Field Correction*, o FFC. Para realizarla es necesario realizar dos procesos, el primero de ellos es la adquisición de una serie de imágenes oscuras, y realizar un promedio de estas; el segundo es la toma de una serie de imágenes de un fondo blanco con una iluminación entre el 30 y 70% de saturación del sensor y promediarlas. Finalmente se aplica la siguiente fórmula:

$$C = (R - D) * G \quad (20)$$

donde R es la imagen obtenida por la cámara sin procesar, o RAW, D es el promedio de las imágenes negras y se multiplica por una ganancia G que se obtiene de la división del promedio cada píxel de imágenes de fondo blanca entre cada píxel de R. El resultado de este proceso se aprecia en la Figura 3.11, la corrección permite observar de mejor forma la imagen, la banda oscura que aparece en la parte superior se debe al filtrado del sensor, en esta zona no hay mediciones aunque se puede apreciar imagen.




Figura 3.11: Imagen al aplicarse la FFC



### 3.4. Recolección de muestras

Para la Tesis se hará el diagnóstico de la roya en hojas de café, por lo que se hizo una recolección de hojas en la comunidad de Puerto del Sabino, en el municipio de Landa de Matamoros, Querétaro. En esta zona la delegación estatal de Sanidad Vegetal se encuentra haciendo controles de roya con los pequeños productores.



Figura 3.12: Hojas en una parcela de Puerto del Sabino, Landa de Matamoros, Querétaro

Los síntomas de la presencia de roya son los puntos amarillos en la hoja, para clasificar el grado de daño el Servicio de Sanidad Vegetal del Gobierno de México emitió una escala de daño según el porcentaje de infección, este se puede ver en la Figura 3.13.




Figura 3.13: Escala de daño según el porcentaje de infección

Para el transporte de las hojas se hizo uso de una prensa botánica, de tal manera que las

hojas pudieran secarse y evitar el crecimiento de moho, en la Figura 3.14 se puede ver como fueron distribuidas las hojas en las diferentes camaras de la prensa botánica.



Figura 3.14: Hojas de café colocadas en la prensa botánica

### 3.5. Procesamiento de las imágenes

Para el proceso de adquisición de imágenes las últimas configuraciones se establecieron de la siguiente forma: la cámara se encuentra a 28 centímetros de distancia del objetivo, el motor se mueve a una velocidad controlada de  $0.6^\circ/s$ . El proceso toma 6.7 minutos por hoja, se requieren 3800 fotografías de cada hoja para poder obtener la reflectancia espectral completa. El número de hojas que se fotografió fue 177 muestras, a continuación se detallará el número de hojas según la categoría.

Categoría	Total
0	44
1	30
2	20
3	31
4	26
5	26
Total	177

Tabla 3.2: Detalle de las muestras de hojas con y sin roya

En la Figura 3.15 se puede observar como se lleva a cabo parte del proceso de escaneo, la hoja debe colocarse sobre una superficie negra para evitar la reflectancia de la luz y que esto afecte las mediciones. El movimiento debe realizarse de forma perpendicular a las líneas del sensor de la cámara.




Figura 3.15: Proceso de escaneo de hojas

Una vez que se han obtenido todas las imágenes de cada una de las hojas es necesario realizar un proceso de *Stiching*, recordemos que el *linescan* contiene todas las mediciones hiperespectrales en una sola fotografía por lo que es necesario hacer la reconstrucción de cada banda espectral.

Cómo se puede observar en la Figura 3.16, en la izquierda se aprecia una imagen donde los fragmentos de la imagen hiperespectral fueron apilados sin embargo no existe un traslape entre foto y foto lo que provoca que exista información repetida, por otro lado en la parte derecha se muestra el apilado de bandas con un traslape del 75 % lo que le da una apariencia adecuada.

Una vez se completa el *stitching* para obtener los índices de vegetación es necesario hacer un acoplamiento de las bandas, ya que la técnica de *linescan* provoca que las bandas se encuentren desplazadas, en la Figura 3.5 se puede ver como 2 bandas se encuentran desplazadas. Para hacer la alineación se utilizó el proceso llamado *Enhanced Correlation Coefficient*,

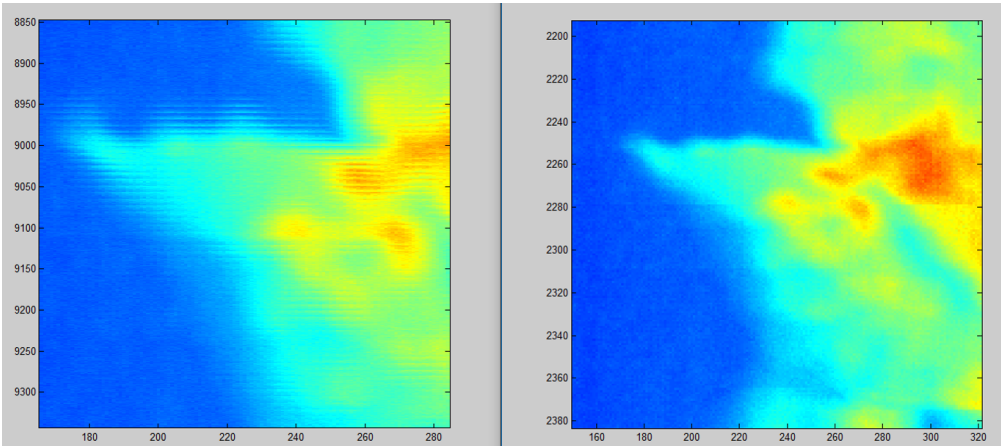


Figura 3.16: Imagen sin traslape vs. Imagen con traslape, ambas con un pseudo coloreado que estima la transformación geométrica entre dos imágenes dando como resultado el desplazamiento de una de las dos imágenes donde el coeficiente de correlación se encuentra maximizado [43].




Figura 3.17: Bandas espectrales sin alinear vs alineadas.

Una vez se han alineado las bandas espectrales es posible obtener los índices de vegetación a los que se les extraerán características para ser usadas como información de entrada para entrenar los algoritmos de *machine learning*. En la Figura 3.18 puede observar el aspecto que tendrás las imágenes al adquirir los índices de vegetación, en este caso específico NDVI.

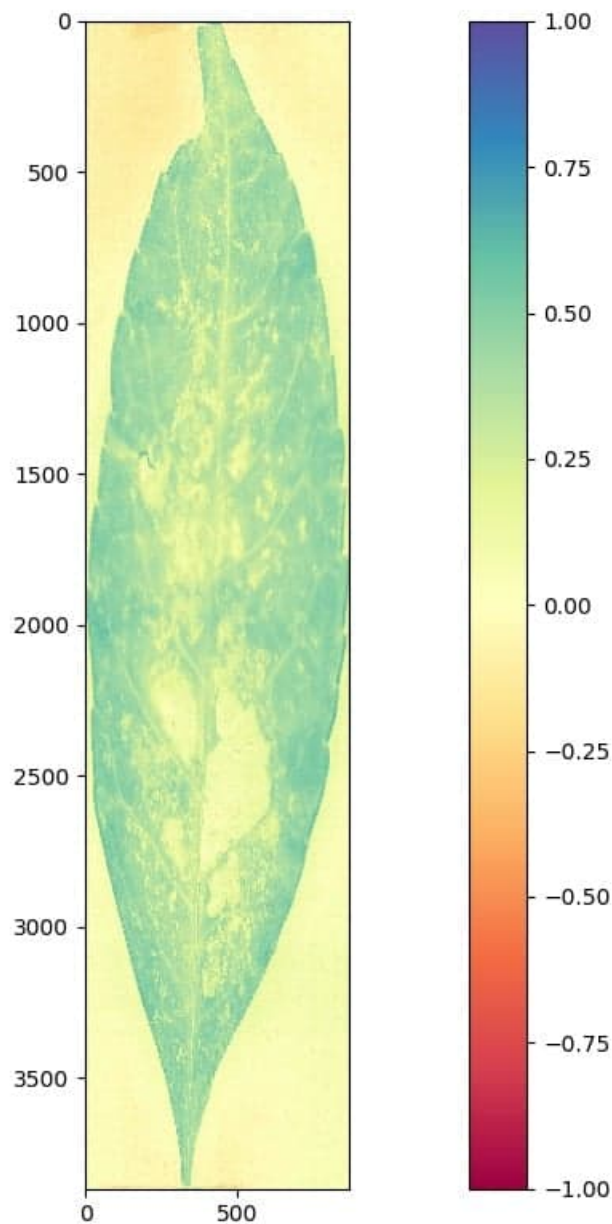


Figura 3.18: NDVI de una hoja

Finalmente, previo al entrenamiento de los diferentes algoritmos de *machine learning*, una vez obtenida la información que describe las imágenes por medio de los histogramas, los momentos de Hu y los *Haralick features*, y almacenada en forma de una base de datos correspondiente a cada uno de los índices de vegetación se realizó un PCA.

En primer lugar se realizó el PCA con 2 componentes, que se pueden ver en la parte izquierda de las Figuras 3.19, 3.20, 3.21, 3.22, 3.23, se puede observar que no hay una relación directa entre el valor de los componentes con su clase, ya que se encuentran mezclados, sin embargo en los de NDVI y NDVI705 es posible encontrar cierta tendencia pese a lo desordenados que puedan parecer.

Posteriormente se realizó el PCA con 3 componentes, que se pueden ver en la parte derecha de las Figuras 3.19, 3.20, 3.21, 3.22, 3.23, en estos solamente en NDVIrededge se puede apreciar que los datos tienen a formar una superficie, en cambio en los demás índices es complicado encontrar alguna relación que permita establecer alguna tendencia.

En la mayoría de los casos que se muestran los componentes únicamente pueden capturar entre el 50 % y el 60 % de la estructura de la información, independientemente si se trata de 2 o 3 componentes, por lo tanto se trata de un problema no lineal.

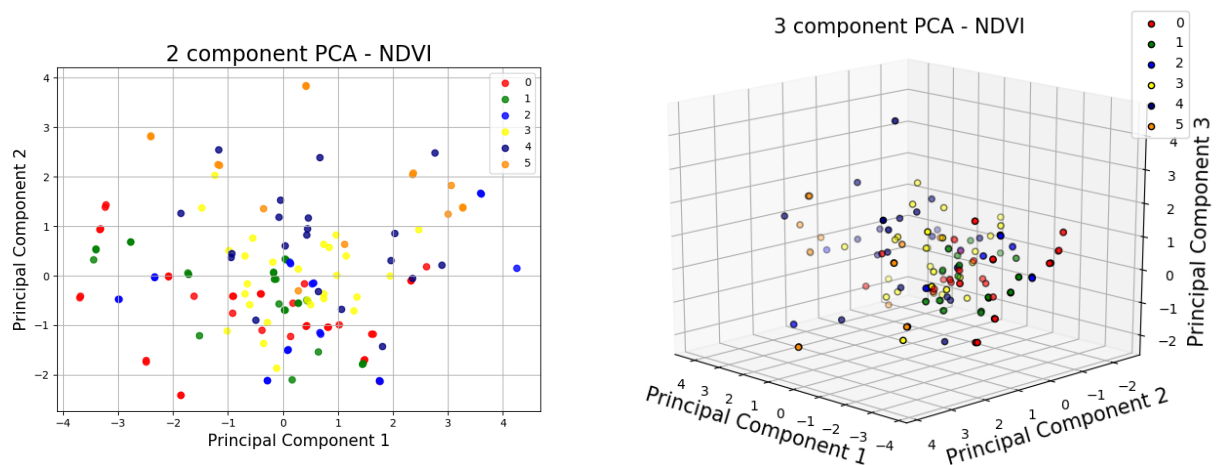


Figura 3.19: PCA de 2 y 3 componentes con NDVI

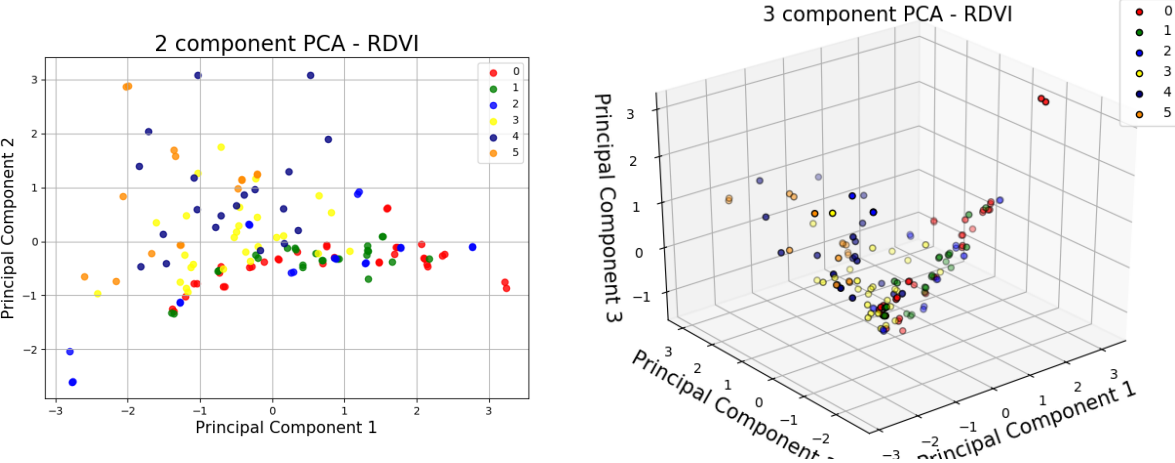


Figura 3.20: PCA de 2 y 3 componentes con RDVI

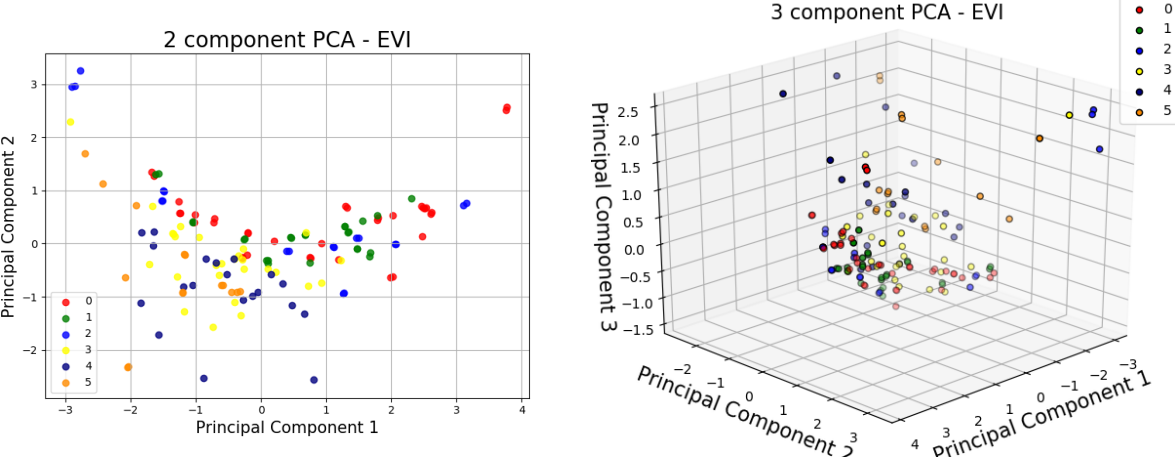


Figura 3.21: PCA de 2 y 3 componentes con EVI




Figura 3.22: PCA de 2 y 3 componentes con NDVI705

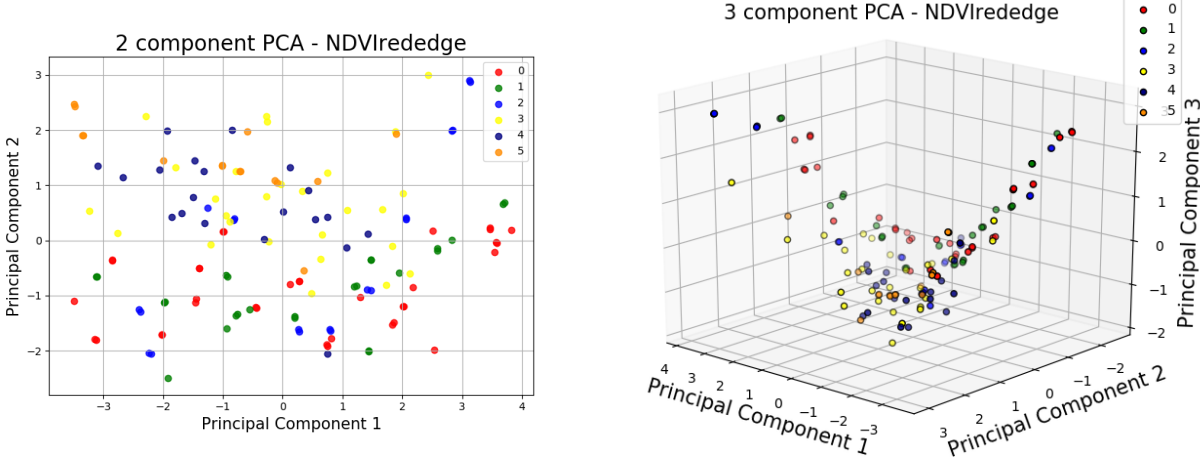


Figura 3.23: PCA de 2 y 3 componentes con NDVIrededge



# Capítulo 4

## Resultados

En este capítulo se muestran los resultados obtenidos del entrenamiento de los tres algoritmos, *Random Forest*, *Support Vector Machine* y *Artificial Neural Network*, con cada uno de los diferentes índices de vegetación que fueron seleccionados para la Tesis, para el experimento se hizo una partición con relación 80:20 de las 177 muestras u hojas que fueron obtenidas de un campo de cultivo, siendo 141 utilizadas como información de entrenamiento y 36 para para realizar pruebas..

### 4.1. Resultados NDVI

En esta sección se muestran los resultados al emplear las imágenes de NDVI con los algoritmos, la Figura 4.1 muestra un diagrama de cajas y bigotes donde se observa una prueba con cada uno de los algoritmos realizando 10 particiones aleatorias del mismo set de información. El análisis muestra que el algoritmo con mejor desempeño es el RF, teniendo una media de las diferentes pruebas de 73% de precisión al clasificar el set de prueba. ANN presenta resultados más variados teniendo como media 68%, y SVM, cuenta con una media de 60% siendo el algoritmo de peor desempeño de los 3.




Figura 4.1: Diagrama de cajas con el desempeño de los algoritmos al emplear NDVI

En la Figura 4.2 se observa los resultados del RF utilizando el NDVI, se puede decir que se trató de una buena prueba ya que únicamente tiene 3 errores en la clase 4, sin embargo no son significativos ya que es se trata de clases continuas, en este caso la 3, la 4, y la 5, y considerando que son las que tienen síntomas más notorios de roya de manera visual es posible corregir el error. En la Tabla 4.1 este clasificador tiene un valor F de 0.91 lo que se puede entender como un buen clasificador.




Figura 4.2: Resultados de la matriz de confusión del RF utilizando NDVI

Precision	Recall	F1-score
<i>0.93</i>	<i>0.92</i>	<i>0.91</i>

Tabla 4.1: Tabla de métricas de RF utilizando NDVI

En la matriz de confusión de la Figura 4.3 se observan los resultados al aplicar SVM junto con NDVI, se observa que comparado con RF existen más errores, 6 en total, es importante resaltar el error que clasifica una hoja de clase 4 como 0, ya que este puede considerarse un error grave ya que la esta tomando como si esta estuviera libre del hongo, al ser detectado por el usuario del código se puede proceder a un ajuste del modelo por ser de las clases que tienen mayor presencia del hongo. Si se toma el valor F de 0.81 en la Tabla 4.2 se puede decir que es un algoritmo relativamente bueno.




Figura 4.3: Resultados de la matriz de confusión del SVM utilizando NDVI

Precision	Recall	F1-score
<i>0.82</i>	<i>0.83</i>	<i>0.81</i>

Tabla 4.2: Tabla de métricas de SVM utilizando NDVI

En la matriz de confusión de la Figura 4.4 se observa el resultado del algoritmo ANN con NDVI, este cuenta con un desempeño inferior al SVM y al RF con el mismo índice de vegetación ya que cometió 7 errores en total, principalmente en la clase 4. la mayoría de los errores se debieron a que el algoritmo asigno una clasificación de una clase superior, lo que

en ocasiones puede ser bueno porque se puede interpretar como una alerta, sin embargo al ser en las categorías de mayor presencia de roya es poco útil. El valor F de 0.77 mostrado en la Tabla 4.3 nos indica que es un algoritmo que aún necesita ser optimizado, por ejemplo, agregando más imágenes de ejemplo.




Figura 4.4: Resultados de la matriz de confusión de la ANN utilizando NDVI

Precision	Recall	F1-score
<i>0.79</i>	<i>0.81</i>	<i>0.77</i>

Tabla 4.3: Tabla de métricas de ANN utilizando NDVI

## 4.2. Resultados RDVI

En esta sección se muestran los resultados obtenidos por los los algoritmos empleando el RDVI, una pequeña variación de NDVI, el diagrama de cajas y bigotes en la Figura 4.1 se genera utilizando la misma técnica de las 10 particiones aleatorias de la base de datos. Se muestra que el RF será el algoritmo con mejor desempeño ya que las pruebas arrojaron una media de 78 % de precisión en la clasificación de las imágenes del set de ejemplo. ANN presenta un comportamiento similar a su contraparte NDVI teniendo una media de 73 % de precisión, aunque tiene mayores probabilidades de obtener resultados inferiores. SVM cuenta

con el peor desempeño promedio de los tres algoritmos al mostrar una media de precisión de 64%, sin embargo es posible que se obtengan mejores resultados ya que la mayor parte de los resultados de prueba se encuentran por encima de la media, sin embargo tanto ANN como SVM no serán capaces de obtener mejores resultados que RF.




Figura 4.5: Diagrama de cajas con el desempeño de los algoritmos al emplear RDVI

En la Figura 4.6 se muestra el desempeño del RF utilizando RDVI, el resultado es parcialmente bueno ya que tuvo problemas al clasificar las hojas en la clase 4, en especial por clasificar las muestras como una clase inferior aunque contigua, esto puede ser un problema si ocurriera en niveles más bajos como la clase 1 o 2 cuando la enfermedad empieza a mostrar síntomas, sin embargo al ser entre la clase 3 y 4 este efecto negativo tiene un menor impacto. El valor F de 0.83 que se presenta en la Tabla 4.4 indica que se trata de un algoritmo clasificador bueno, la precisión de 0.91 que muestra se puede considerar como buena ya que no alcanza a clasificar todo, como si se hubiera memorizado los datos del entrenamiento, lo que podría traducirse como un sobreentrenamiento, en cambio en lo general produce un buen resultado.

Precision	Recall	F1-score
<i>0.91</i>	<i>0.86</i>	<i>0.83</i>

Tabla 4.4: Tabla de métricas de RF utilizando RDVI




Figura 4.6: Resultados de la matriz de confusión de RF utilizando RDVI

En la matriz de la Figura 4.7 se observan los resultados obtenidos al entrenar el algoritmo SVM empleando el índice RDVI. Se observa que el desempeño del algoritmo puede ser categorizado como un resultado deficiente al tener un total de 13 errores, teniendo algunos graves en dos de las clases, la 1 y la 4, siendo la primera la peor, ya que indica que las muestras no tienen presencia de roya.

La Tabla 4.5 nos muestra que el resultado de precisión es de 0.68 lo que indica que un 30 % de los datos no serán clasificados correctamente, así mismo muestra que el valor F es de 0.64 lo que se traduce como un algoritmo que no es capaz de generar un modelo que capture la distribución de la información, en otras palabras es un subentrenamiento.

Para combatir el subentrenamiento existen algunas técnicas, entre ellas lo más recomendable es la adquisición de un mayor número de muestras o la generación de estas para que el algoritmo se capaz de capturar de mejor forma la estructura de la información, se suele preferir la segunda debido a que reduce los costos y los tiempos de adquisición.

Precision	Recall	F1-score
<i>0.68</i>	<i>0.64</i>	<i>0.64</i>

Tabla 4.5: Tabla de métricas de SVM utilizando RDVI

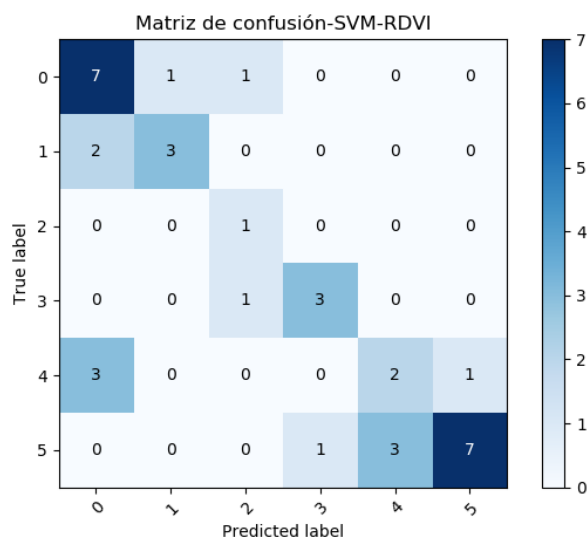


Figura 4.7: Resultados de la matriz de confusión de SVM utilizando RDVI

En la matriz de la Figura 4.8 que el resultado del uso de la ANN con RDVI produce un resultado similar al del SVM pero con un resultado peor, el número de errores es el mismo 13, sin embargo su distribución es lo que se traduce en un desempeño inferior. En este algoritmo se pueden ver los errores estadísticos de tipo 1 y tipo 2, donde el primero es el que produce falsos positivos, localizados del lado derecho de la diagonal principal, y los últimos falsos negativos que se encuentran a la izquierda de la diagonal principal.

Los errores del tipo 2 son más graves, en este caso, al clasificar hojas en clases inferiores respecto al porcentaje de infección que se tiene, principalmente los dos que se encuentran clasificando muestras de la clase 1 como 0, ya que puede producir un mal diagnóstico y con esto que el hongo pueda expandirse rápidamente. En el caso de los tres que son clase 4 y se clasifican como clase 0, sus características visuales permitirían que se detecte rápidamente el error y no tenga gran impacto. El valor F correspondiente de 0.60 que muestra la Tabla 4.6 indica que el modelo generado por este algoritmo necesita mejorarse para que sea capaz de identificar la estructura de los datos de las muestras para realizar una clasificación adecuada.

Precision	Recall	F1-score
<i>0.65</i>	<i>0.61</i>	<i>0.60</i>

Tabla 4.6: Tabla de métricas de ANN utilizando RDVI




Figura 4.8: Resultados de la matriz de confusión de ANN utilizando RDVI

### 4.3. Resultados EVI

En esta sección se muestran los resultados del entrenamiento de los tres algoritmos utilizando las imágenes del índice EVI. Como se puede observar en la Figura 4.9, el diagrama de cajas y bigotes nos muestra que RF será de nueva cuenta el algoritmo que tenga mejor desempeño teniendo una media de 82 % de precisión al realizar las diez pruebas aleatorias, sin embargo existe una mayor posibilidad de que el resultado sea inferior al contener más pruebas distribuidas por debajo de la media.

Por su parte SVM presenta un comportamiento irregular al tener dos pruebas atípicas en la parte superior, la media que presenta es del 62 % lo que podría indicar que es necesario la obtención de un mayor número de imágenes para incrementar el entrenamiento, también es importante resaltar que las demás pruebas tuvieron resultados cerca de la media por los que no hay mucha dispersión.

ANN se presenta con una media de 70 % de precisión en la realización de las pruebas, sin embargo, la mayor parte de estas se encuentran por debajo del promedio al mostrar una distribución con tendencias a valores inferiores, sin embargo los resultados no superarán a los que presenta RF.






Figura 4.9: Diagrama de cajas con el desempeño de los algoritmos al emplear EVI

En la matriz de la Figura 4.10 se observa el resultado de una prueba de RF con el índice EVI, se observa que los resultados presentan un comportamiento similar a los presentados en los dos índices de vegetación anteriores, sin embargo el desempeño es deficiente, ya que al revisar la Tabla 4.7 se aprecia que la precisión se encuentra en 75% y el valor F en 0.76 por lo que el resultado es regular en realidad, en especial por haber clasificado una hoja de la clase 3 como 0, lo que es importante ya que fue clasificado como sin enfermedad.




Figura 4.10: Resultados de la matriz de confusión de RF utilizando EVI

Precision	Recall	F1-score
<i>0.75</i>	<i>0.78</i>	<i>0.76</i>

Tabla 4.7: Tabla de métricas de RF utilizando EVI

En la Figura 4.11 se muestra la matriz de confusión del SVM empleando el índice EVI como datos de entrada, se aprecia que tiene un mal desempeño al tener un total de 16 errores. De estos errores, el más grave es el que clasifica las muestras como clase 0, sin roya, cuando en realidad son clase 1, en segundo lugar es el clase 4 que fue clasificado como clase 1, sin embargo este es el caso donde la inspección visual puede ayudar a corregir el problema, por último están los 8 errores de clasificación en la clase 5, 4 para clase 3 y cuatro para clase 4, en estos solo existe la diferencia del porcentaje de infección. Si se observan los valores en la Tabla 4.8, aunque el algoritmo cuenta con una precisión de 74 %, el valor F de 0.55 indica que es un clasificador muy malo y que debe ser entrenado de nueva cuenta.




Figura 4.11: Resultados de la matriz de confusión de SVM utilizando EVI

Precision	Recall	F1-score
<i>0.74</i>	<i>0.56</i>	<i>0.55</i>

Tabla 4.8: Tabla de métricas de SVM utilizando EVI

La matriz de confusión de la Figura 4.12, que presenta los resultados de ANN empleando EVI, se puede observar que el algoritmo tuvo un desempeño similar al SVM teniendo problemas

de clasificación en las clases con mayor presencia de roya, la 4 y la 5, sin embargo en las clase clases 1 y 2, donde comienza la aparición de la roya, su comportamiento es adecuado, incluso con el error que comete. El algoritmo se puede considerar con resultados regulares si observamos el valor F en la Tabla 4.9 ya que 0.66, lo que quiere decir que es necesaria la adquisición de más imágenes de ejemplo o la generación de las mismas.




Figura 4.12: Resultados de la matriz de confusión de ANN utilizando EVI

Precision	Recall	F1-score
<i>0.72</i>	<i>0.67</i>	<i>0.66</i>

Tabla 4.9: Tabla de métricas de ANN utilizando EVI

#### 4.4. Resultados NDVI705

En esta sección se muestran los resultados obtenidos con los tres algoritmos empleando el índice de vegetación que se le denominó NDVI705. En el diagrama de cajas y bigotes de la Figura 4.13 se puede observar que el RF tiene uno de los mejores resultados con una media de precisión de 82%, con una distribución equilibrada entre los resultados mayores y menores a la media. En el caso del SVM cuenta con datos atípicos lo que indica que este algoritmo no es constante en sus resultados, su media se encuentra en 65% por lo que es posible que necesite

la adquisición de más muestras. En el caso de ANN su media se encuentra en 65 % por lo que también será necesaria la adquisición de un mayor número de imágenes para incrementar su precisión, en el gráfico se aprecia que los resultados no podrán superar lo hecho por RF y en general serán mejores que los que otorgue SVM.




Figura 4.13: Diagrama de cajas con el desempeño de los algoritmos al emplear NDVI705

En la matriz de confusión de la Figura 4.14 se muestra el resultado de entrenar el RF con el NDVI705, como se puede observar solamente obtuvo 2 errores al clasificar, ambos en la clase 4 clasificando uno como 3 y otro como 5, lo que indica que este modelo fue capaz de capturar la distribución de la información de gran forma.

Al compararlo con la Tabla 4.14 se observa que el valor de precisión, de 95 %, y el valor F, de 0.94, indican que se trata de un clasificador excelente. Gracias a que no llega a tener un resultado perfecto se puede decir que es capaz de generalizar correctamente la información, con lo que se evita el sobreentrenamiento, por lo que en caso de utilizarse con muestras nuevas será capaz de clasificar adecuadamente.

Precision	Recall	F1-score
<i>0.95</i>	<i>0.94</i>	<i>0.94</i>

Tabla 4.10: Tabla de métricas de RF utilizando NDVI705




Figura 4.14: Resultados de la matriz de confusión de RF utilizando NDVI705

La matriz de confusión del SVM utilizando NDVI705, que puede verse en la Figura 4.15, nos muestra que fue un clasificador con pocos errores, 6 en total. Si se observa la Tabla 4.11, se observa que tiene un valor F de 0.84 lo que indica que es un buen clasificador, sin embargo es importante no olvidar lo que se ve en la Figura 4.13, ya que esta prueba fue uno de esos casos atípicos, por lo que el potencial de este algoritmo es aún mayor que lo mostrado en el diagrama.




Figura 4.15: Resultados de la matriz de confusión de SVM utilizando NDVI705

Precision	Recall	F1-score
<i>0.87</i>	<i>0.83</i>	<i>0.84</i>

Tabla 4.11: Tabla de métricas de SVM utilizando NDVI705

En la matriz de confusión de la Figura 4.16, se observa que el algoritmo ANN tiene un desempeño aceptable con 7 errores en total, como punto favorable tiene que es capaz de identificar en gran medida las etapas tempranas de la roya, lo que conduce a un control adecuado, como punto negativo es la cantidad de errores que tiene al clasificar elementos de la clase 5 como si fueran clase 4. En la Tabla 4.12 se tiene que el valor F es de 0.78 lo que indica que es un clasificador aceptable sin embargo puede mejorar.




Figura 4.16: Resultados de la matriz de confusión de ANN utilizando NDVI705

Precision	Recall	F1-score
<i>0.81</i>	<i>0.78</i>	<i>0.78</i>

Tabla 4.12: Tabla de métricas de ANN utilizando NDVI705

## 4.5. Resultados NDVIrededge

En esta última sección se muestran los resultados del entrenamiento de los algoritmos con el último índice de vegetación que se le nombro como NDVIrededge. En el diagrama de

cajas y bigotes de la Figura 4.17 se observa que comparado con el índice anterior, todos los resultados en promedio disminuyeron su desempeño. El RF es el algoritmo que presenta menos consistencia al tener dos datos atípicos por encima y debajo de la media. SVM, con una media de 62%, puede presentar resultados aceptables ya que la mayor parte de las pruebas se establecieron por encima de la media. ANN, con una media de 65%, es posible que presente resultados inferiores a SVC debido a que en la mayor parte de las pruebas se distribuyeron por debajo de la media de SVC y algunas incluso por debajo de SVC.

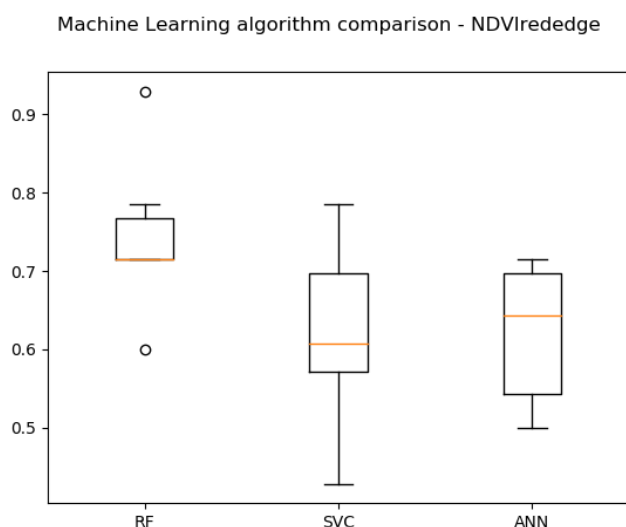


Figura 4.17: Diagrama de cajas con el desempeño de los algoritmos al emplear NDVIrededge

En la Figura 4.18, donde se muestra la matriz de confusión de RF con NDVIrededge, se aprecia que este clasificador tuvo un buen comportamiento teniendo únicamente cuatro errores y estos en las dos clases con mayores síntomas visuales. Por otra parte las etapas iniciales fueron correctamente clasificadas, esto es importante debido a la intención de encontrar signos tempranos para un control adecuado de roya. Finalmente al observar la Tabla 4.13 y comprar que el valor F es de 0.88 nos indica que es un clasificador bueno, puede mejorar, pero es aceptable para ejecutar su tarea.

Precision	Recall	F1-score
<i>0.89</i>	<i>0.89</i>	<i>0.88</i>

Tabla 4.13: Tabla de métricas de RF utilizando NDVIrededge

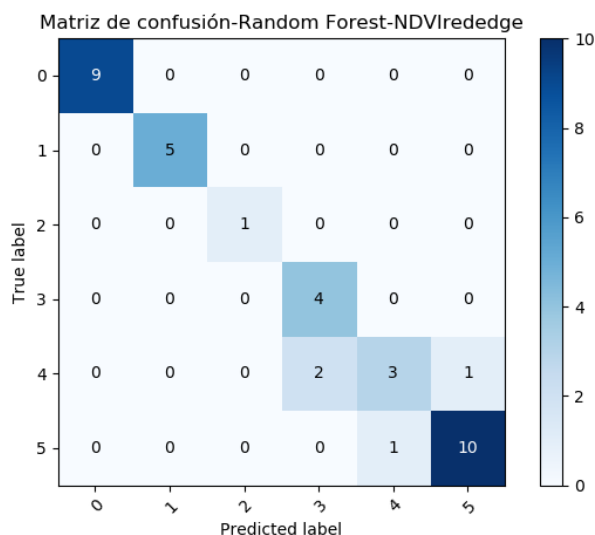


Figura 4.18: Resultados de la matriz de confusión de RF utilizando NDVIrededge

La matriz de confusión de la Figura 4.19 muestra el resultado de entrenar el SVM con el índice NDVIrededge, como se observa el clasificador tuvo 11 errores, lo representa una gran parte de los datos de muestra, aunque tiene un buen comportamiento en las clases donde hay etapas tempranas de la aparición de la roya. En la Tabla 4.14 se observa que tiene un valor F de 0.69 lo que significa que es un clasificador deficiente y que es necesaria la obtención de más muestras para poder mejorar su desempeño.




Figura 4.19: Resultados de la matriz de confusión de SVM utilizando NDVIrededge



Precision	Recall	F1-score
<i>0.68</i>	<i>0.69</i>	<i>0.69</i>

Tabla 4.14: Tabla de métricas de SVM utilizando NDVIrededge

La matriz de confusión de la Figura 4.20 muestra que ANN tuvo un desempeño similar al del SVM, con 12 errores en total, con el valor F de 0.64 que se muestra en la Tabla 4.15 se puede concluir que es un algoritmo que aún necesita más entrenamiento así como mayor número de muestras, ya que esta cayendo en un subentrenamiento.

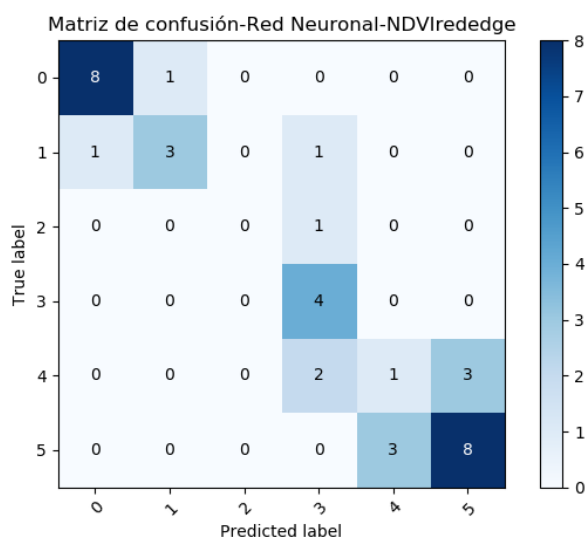


Figura 4.20: Resultados de la matriz de confusión de ANN utilizando NDVIrededge

Precision	Recall	F1-score
<i>0.65</i>	<i>0.67</i>	<i>0.64</i>

Tabla 4.15: Tabla de métricas de ANN utilizando NDVIrededge

# Capítulo 5

## Conclusiones

En esta Tesis se buscó la implementación de un sistema experto que fuera capaz de utilizar conocimiento especializado para la resolución de un problema específico, la detección de roya en cafetales. Los resultados de la experimentación expresados en las matrices de confusión confirman que es posible la clasificación de la roya en sus diferentes etapas según el porcentaje de infección en las hojas.

De igual forma se puede concluir que las imágenes hiperespectrales presentan una opción viable para ser utilizadas como una herramienta de apoyo en el diagnóstico de enfermedades en plantas, no únicamente la roya, ya que permiten observar el estado fotosintético del tejido interno de las hojas utilizando la reflectancia del espectro infrarrojo, especialmente con el uso de los índices de vegetación los cuales mejoran la observación de las zonas afectadas en las etapas de menor infección en las hojas.

De los diferentes índices de vegetación que fueron utilizados en conjunto con los algoritmos de inteligencia artificial en esta Tesis, el que se denominó como NDVI705 fue el cual obtuvo el mejor desempeño, teniendo una precisión de hasta el 95 %, con esto se puede concluir que este índice no tiene saturación en comparación con el NDVI y puede mostrar de mejor forma las zonas dañadas, también se comprueba por medio de este índice que las bandas espectrales que se encuentran en la zona del *rededge* son mejores para detectar los pequeños cambios en la cantidad de material fotosintético.

Los algoritmos que utilizaron el índice EVI fueron los que tuvieron los peores resultados en

general ya que tuvo una precisión únicamente de 72% y 75% por lo que no se recomienda su uso para la detección de pequeños detalles como las primeras pústulas que aparecen en las primeras etapas de la roya. El NDVIrededge tampoco se recomienda ya que aunque tiene un resultado bueno de 89% de precisión, este solo se presenta en uno de los algoritmos utilizados, mientras en los otros dos fue de 69% y 65%.

Respecto a los algoritmos que se utilizaron, *Random Forest* fue el que consiguió los mejores resultados, de hasta 95% de precisión al utilizar el índice NDVI705. Es posible que se deba a la naturaleza no lineal de la información, ya que al hacer el análisis de componentes principales de 2 y de 3 componentes se puede apreciar que no hay una separación perfectamente lineal entre las diferentes clases.

Los algoritmos restantes, las redes neuronales y *Support Vector Machine*, presentan resultados similares en lo que se refiere a la precisión, sin embargo los valores de exhaustividad son muy bajos con excepción de los casos donde se combina con los índices NDVI y NDVI705, por lo que al observar los valores F se puede observar que son resultados deficientes y se necesitan una mayor cantidad de ejemplos para mejorar su desempeño.

Teniendo en cuenta lo complicado que puede resultar la clasificación de imágenes según el porcentaje de infección en la hoja, los resultados que presenta esta Tesis son aceptables, se pudo encontrar cual de los índices seleccionados funciona mejor para identificar las pequeñas diferencias entre ellas.

Aunque se mostró que la metodología seleccionada funcionó, resulta obvio que este sistema aún es perfectible y que existen algunas modificaciones que pueden añadirse para hacer que se obtengan mejores resultados, por ejemplo la creación de una base de datos de mayor tamaño, con la que se puedan tener datos históricos de algunas variables como la temperatura y la humedad, o el uso de algún otro método para la extracción de características adicional a los 3 utilizados. Lo ideal sería que estos algoritmos trabajaran en una aplicación para que el usuario pueda interactuar y no sea necesario tener el conocimiento de que parte del código es necesario ejecutar.

# Capítulo 6

## Recomendaciones

La detección de enfermedades, no únicamente de la roya en el cafeto, es una tarea que se debe continuar investigando, entre las recomendaciones para trabajos futuros se encuentra el uso de otras cámaras, por ejemplo alguna que pueda obtener la reflectancia del espectro visible y el infrarrojo cercano, esto con la idea de poder probar índices de vegetación que utilizan las bandas verdes para su cálculo.

Mediante el uso de las bandas que se encuentran en la zona del *red edge* se obtuvieron buenos resultados, por lo que su uso en la detección de las concentraciones de clorofila debe continuar, existen otros índices similares al NDVI por lo que es posible que tengan buenos resultados para el diagnóstico de enfermedades.

En los algoritmos de clasificación, tener una mayor cantidad de estratos provoca que sea más sencillo cometer errores. Cómo se desea hacer una detección temprana de la enfermedad es posible la implementación de un clasificador que solamente tenga dos estados, con y sin enfermedad, por lo que el uso de las hojas de las clases 3, 4 y 5, se haría innecesario, ya que estas puede clasificarlas quién este haciendo la inspección visual y solo se recomendaría en caso de querer conocer la severidad del daño en el tejido.

Por último, el banco de pruebas de este proyecto fue una adaptación de infraestructura existente, sin embargo se puede hacer más pequeño para que pueda ser transportado o en su defecto cambiar el modo de adquisición a el uso de un vehículo no tripulado como un drone, para que no sea necesario el transporte de las hojas a un laboratorio.

# Bibliografía

- [1] Honorato Júnior, J., Zambolim, L., Aucique-Pérez, C. E., Resende, R. S., & Rodrigues, F. A. Photosynthetic and antioxidative alterations in coffee leaves caused by epoxiconazole and pyraclostrobin sprays and *Hemileia vastatrix* infection. *Pesticide Biochemistry and Physiology*, 123, 31–39, (2015).
- [2] J.M. Waller, Coffee rust—epidemiology and control, *Crop Protection*, Volume 1, Issue 4, Pages 385-404, (1982).
- [3] D. Corrales, A. Figueroa, A. Ledezma Espino, and J. Corrales, “Two-Level Classifier Ensembles for Coffee Rust Estimation in Colombian Crops”, *Int. J. Agric. Environ. Inf. Syst.*, vol. 7, pp. 41–59, (2016).
- [4] West, J. S., Bravo, C., Oberti, R., Lemaire, D., Moshou, D., & McCartney, H. A. The potential of optical canopy measurement for targeted control of field crop disease. *Annual Reviews of Phytopathology*, 41, 593–614 (2003).
- [5] Huang, W.; Lamb, D.W.; Niu, Z.; Zhang, Y.; Liu, L.; Wang, J. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. *Precis. Agric.*, 8, 187–119 (2007).
- [6] Su H, Du Q, Chen G, Du P. Optimized hyperspectral band selection using particle swarm optimization. *IEEE J Sel Top Appl Earth Obs Remote Sens.* ;7:2659–70 (2014).
- [7] Z. Jiang et al., Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction, *Remote Sens. Environ.*, vol. 101, no. 3, pp. 366–378, (2006).

- [8] Feng, W., Shen, W., He, L., Duan, J., Guo, B., Li, Y., et al. Improved remote sensing detection of wheat powdery mildew using dual-green vegetation indices. *Precision Agriculture*, 17(5), 608–627 (2016).
- [9] Huang, W., Lamb, D. W., Niu, Z., Zhang, Y., Liu, L., & Wang, J. Identification of yellow rust in wheat using *in-situ* spectral reflectance measurements and airborne hyperspectral imaging. *Precision Agriculture*, 8(4), 187–197 (2007).
- [10] Arnal Barbedo, J., Vieira Koenigkan, L., Teixeira Santos, T., Identifying multiple plant diseases using digital image processing, *Biosystems Engineering*, Volume 147, Pages 104-116 (2016).
- [11] Pérez-Ariza, C. B., Nicholson, A. E., Flores, M. J. Prediction of Coffee Rust Disease Using Bayesian Networks. Sixth European Workshop on Probabilistic Graphical Models, 259-266 (2012).
- [12] SENASICA, Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria . Manual técnico para el manejo preventivo de la roya del cafeto (2013). México, D.F.
- [13] SENASICA. 2016. Roya del cafeto (*Hemileia vastatrix* Berkeley & Broome). Dirección General de Sanidad Vegetal. Programa de Vigilancia Epidemiológica Fitosanitaria. México, D.F. Ficha Técnica No. 40. 23 p.
- [14] LAND INFO Worldwide Mapping, LLC, "Buying Satellite Imagery: Pricing Information for High Resolution Satellite Imagery", 2018. [Online]. Disponible en: <http://www.landinfo.com/satellite-imagery-pricing.html>. [Visitado 27-Mar-2018]
- [15] United States Geological Survey (USGS), "Landsat 8", 2017. [Online]. Disponible en: <https://www.usgs.gov/land-resources/nli/landsat/landsat-8>. [Visitado 27-Mar-2018]
- [16] European Space Agency (ESA), "SENTINEL-2", 2017 [Online]. Disponible en: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>. [Visitado 27-Mar-2018]
- [17] J. M. Waller, "Coffee rust—epidemiology and control," *Crop Prot.*, vol. 1, no. 4, pp. 385–404, (1982).

- [18] Servicio de Información Agroalimentaria y Pesquera (SIAP). Atlas agroalimentario 2012-2018. Primera edición (2018).
- [19] Alpaydin, E. Introduction to machine learning/ Ethem Alpaydin. — 2nd. MIT Press (2010).
- [20] Müller, A. C., Guido, S. Introduction to machine learning with python. O'Reilly Media Inc. United States of America (2017).
- [21] Géron, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow. O'Reilly Media Inc. United States of America (2017).
- [22] Stuart J. R., Peter N. Artificial Intelligence: A Modern Approach, Third Edition, Prentice Hall (2010).
- [23] J. G. Carbonell, R. S. Michalski, and T. M. Mitchell, "Machine learning: A historical and methodological analysis," AI Magazine, vol. 4, no. 3, pp. 69–79 (1983).
- [24] Cortes, C. and Vapnik, V. Support-Vector Networks. Machine Learning, 20, 273-297 (1995).
- [25] Quinlan, J. R. Induction of Decision Trees, Machine Learning, 1(1), 81-106 (1986).
- [26] A., & Bengio, Y. Deep Sparse Rectifier Neural Networks. AISTATS, 15, pp. 315-323 (2011).
- [27] Ming-Kuei Hu, "Visual pattern recognition by moment invariants,in IRE Transactions on Information Theory, vol. 8, no. 2, pp. 179-187, February 1962.
- [28] Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. IEEE Transactions on Systems, Man, and Cybernetics, SMC-3(6), 610–621.
- [29] R. E. Madsen, L. K. Hansen, O. Winther, "Singular value decomposition and principal component analysis", Neural Netw., vol. 1, pp. 1-5, Feb. (2004).

- [30] R. N. Clark, G. A. Swayze, K. E. Livo, R. F. Kokaly, S. J. Sutley, J. B. Dalton, R. R. McDougal and C. A. Gent, Imaging spectroscopy : Earth and planetary remote sensing with the usgs tetracorder and expert systems, *Journal of Geophysical Research : Planets*, vol. 108, no. E12, 2003.
- [31] Farrand W.H., "Hyperspectral remote sensing of land and the atmosphere," *Encyclopedia of Modern Optics*, 1, pp. 395–403 (2005).
- [32] C.-I. Chang, *Hyperspectral Imaging : Techniques for Spectral Detection and Classification*, Kluwer Academic/Plenum Publishing Co., New York, 2003.
- [33] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao, and L. G. Ferreira, "Overview of the radiometric and biophysical performance of the MODIS vegetation indices," *Remote Sens. Environ.*, vol. 83, no. 1/2, pp. 195–213, Nov. 2002.
- [34] Towers, P. 2002. *Conceptos Iniciales sobre Teledetección y su Aplicación al Agro*. Buenos Aires, 138 p
- [35] Rouse, J.W., R.H. Haas, J.A. Schell, and D.W. Deering (1974). Monitoring vegetation systems in Great Plains with ERST. *Proceedings of the 3rd ERST Symposium*, NASA SP351, 309-317
- [36] Dehaan, R. (2016). Evaluation of Unmanned Aerial Vehicle (UAV) -Derived imagery for the detection of Wild Radish in Wheat. <https://doi.org/10.13140/RG.2.1.1106.3925>
- [37] Ruiz de la Hermosa, R., Carnero, M. C., "Implementación de un sistema de diagnóstico y alarma basado en termografía en el equipamiento asistencial crítico de un hospital", en 4th International Conference on Industrial Engineering and Industrial Management XIV, 2010.
- [38] Roujean, J., and F. Breon. "Estimating PAR Absorbed by Vegetation from Bidirectional Reflectance Measurements." *Remote Sensing of Environment* 51 (1995): 375-384.



- [39] Gitelson, A., and M. Merzlyak. "Spectral Reflectance Changes Associated with Autumn Senescence of *Aesculus Hippocastanum* L. and *Acer Platanoides* L. Leaves." *Journal of Plant Physiology* 143 (1994): 286-292.
- [40] Miura, T., Yoshioka, H., Fujiwara, K., & Yamamoto, H. (2008). Inter-Comparison of ASTER and MODIS Surface Reflectance and Vegetation Index Products for Synergistic Applications to Natural Resource Monitoring. *Sensors*, 8(4), 2480–2499.
- [41] Huete, A.; Didan, K.; van Leeuwen, W.; Miura, T.; Glenn, E. MODIS Vegetation Indices. *Land Remote Sensing and Global Environmental Change: NASA's Earth Observing System and the Science of ASTER and MODIS*. (in press); 2008
- [42] CLOUTIS, E. A., CONNERY, D. R., MAJOR, D. J., & DOVER, F. J. (1996). Airborne multi-spectral monitoring of agricultural crop status: effect of time of year, crop type and crop condition parameter. *International Journal of Remote Sensing*, 17(13), 2579–2601.
- [43] Evangelidis GD, Psarakis EZ (2008) Parametric image alignment using enhanced correlation coefficient maximization. *IEEE Trans Pattern Anal Mach Intell* 30(10):1858–18650