



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

**Una revisión: Uso de imágenes satelitales para la detección
de plagas y enfermedades en cultivos**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:
Ingeniero Ambiental**

AUTORES:

Gomez Cordova, Evelyn Milagritos (ORCID: 0000-0002-5908-6131)

Sandoval Morales, Evelyn (ORCID: 0000-0001-9817-329X)

ASESOR:

Dr. Valdiviezo Gonzales, Lorgio Gilberto (ORCID: 0000-0002-8200-4640)

LÍNEA DE INVESTIGACIÓN:

Calidad y Gestión de los Recursos Naturales

LIMA – PERU

2020

Dedicatoria

El presente trabajo investigativo lo dedicamos a nuestras madres por ser la forjadora principal en nuestros caminos de la vida, con su amor, trabajo y sacrificio hemos logrado llegar a cumplir esta meta.

A todos los familiares, amigos y docentes que nos apoyaron y han hecho que se a realizar con éxito este proyecto.

Agradecimiento

Agradecemos a nuestras madres: Guille Córdova e Inés Morales por ser las principales promotoras de nuestros sueños, por confiar y creer en nuestras expectativas, por los valores, consejos y principios que nos han inculcado.

A todos vuestros familiares, amigos, docentes, colegas y jefes de vuestras áreas de trabajo en esta trayectoria universitaria incondicionalmente nos apoyaron.

También expresar nuestro sincero agradecimiento a los Mg. Kevin Sánchez y Dr. Lorgio Valdiviezo por la colaboración durante todo este proceso, donde compartieron sus enseñanza, conocimiento y experiencia para la elaboración de este proyecto

Índice de contenido

Carátula.....	ii
Dedicatoria.....	iii
Agradecimiento	iv
Índice de contenido	7
Índice de tablas.....	8
Índice de gráficos y figuras	9
Índice de abreviaturas.....	10
Resumen	11
Abstract	12
I. INTRODUCCION	13
II. MARCO TEORICO.....	16
III. MÉTODO	37
3.1. Tipo y diseño de investigación	38
3.2. Categorías, subcategorías y matriz de categorización apriorística	38
3.3. Escenario de estudio	41
3.4. Participantes	41
3.5. Técnica e instrumentos de recolección de datos	41
3.6. Procedimientos	41
3.7. Rigor Científico	46
3.8. Método de análisis de información	46
3.9. Aspectos éticos	46
IV. RESULTADOS Y DISCUSION.....	48
V. CONCLUSIONES.....	57
VI. RECOMENDACIONES.....	60
REFERENCIAS BIBLIOGRAFICAS	62
ANEXOS.....	81

Índice de tablas

Tabla 01	Estudios sobre detección de enfermedades y plagas de plantas usando técnicas de procesamiento de imágenes	18
Tabla 02	Rango de las ondas espectrales	23
Tabla 03	Sensores para el monitoreo de la vegetación	27
Tabla 04	Principales sitios web para descargar imágenes satelitales gratuitas	28
Tabla 05	Índices de vegetación utilizados en estudios para detección de enfermedades y plagas	30
Tabla 06	Categoría, Subcategoría y matriz de categorización apriorística	39
Tabla 07	Resumen de criterios de búsqueda de información	43
Tabla 08	Índices de vegetación y coeficiente de determinación R^2	49
Tabla 09	Algoritmos de clasificación Red Neural Artificial (ANN), Soporte de Maquina Vectorial (SVM) y su coeficiente de determinación (R^2)	52
Tabla 10	Algoritmos de segmentación de Intensidad de saturación de color (HSI), Algoritmo K-means clustering y Algoritmo Umbral de Otsu y su porcentaje de aceptación	54

Índice de gráficos y figuras

Figura 1	Firmas espectrales de la vegetación sana y enferma entre las bandas del visible e infrarrojo cercano.	24
Figura 2	Procedimientos básicos para detección de enfermedades y plagas.	25
Figura 3	Imagen en color RGB (rojo, verde y azul)	26
Figura 4	Esquema de Red Neutral ANN	32
Figura 5	Clasificación por Soporte de máquinas vectoriales	33
Figura 6	Imágenes originales e imágenes segmentadas de la hoja de arroz infectado	35
Figura 7	Proceso de elaboración de una revisión bibliográfica.	42
Figura 8	Diagrama de flujo de selección de artículo muestran el coeficiente de determinación de cada índice de vegetación.	43
Figura 9	Gráfico de barras de los índices de vegetación relacionado con el coeficiente de determinación R ² .	51
Figura 10	Gráfico de barra de los Algoritmos de clasificación ANN y SVM	53
Figura 11	Gráfico de los algoritmos de segmentación relacionado con el coeficiente de determinación R ² .	55

Índice de abreviaturas

- ANN: redes neuronales artificiales
- CNN: Red Neural convencional
- ESA: European Space Agency
- FAO: Organización de la Naciones Unidas para la Alimentación y la Agricultura
- GNDVI: Índice de Vegetación Normalizado Verde
- HIS: Intensidad de Saturación de Color
- IV : índices de vegetación
- LDA: Análisis discriminante línea.
- MCARI: Clorofila modificada (a y b) absorción en reflectancia índice
- MIR: reflectancia espectral Infrarrojo medio
- MSI: Índice de estrés por humedad
- NDVI: Índice de vegetación de Diferencia Normalizada
- NIR: reflectancia espectral del canal infrarrojo cercano
- QDA: Análisis discriminante cuadrático.
- PRI: Índice de Reflectancia Fotoquímica
- RVSI: Índice de estrés vegetativo de borde rojo (RVSI)
- SAVI: Índice de vegetación ajustado al suelo
- SIG: Sistemas de Información Geográfica
- SVM: Las máquinas de vectores portuarios
- SWIR: reflectancia corregida atmosféricamente correspondiente al I rojo del visible
- TIR: reflectancia espectral Onda Térmica
- UV: Rayos ultravioleta
- VARI: Visible atmosféricamente índice de resistencia
- VIS: reflectancia espectral Visible
- WI: Índice de agua.

Resumen

En esta investigación tiene como objetivo explicar los procesos metodológicos de procesamiento de imágenes satelitales para la detección de plagas y enfermedades, asimismo revisar los principales índices de vegetación y describir los algoritmos de segmentación y clasificación utilizados. Para ello, se realizó la extracción de información de artículos, libros, paginas institucionales y tesis priorizándose una antigüedad no mayor a 5 años. De acuerdo con el número total de consultas, son 68 documentos que han sido seleccionado como la base principal para este estudio, teniendo como resultado que el coeficiente de determinación R^2 del SR es el mayor con 89.00%, mientras PRI, NDVI y GNDVI son los índices más utilizados en las investigaciones para la detección de plagas y enfermedades con un 70%, 50%, 50% respectivamente. Entre los algoritmos de clasificación, el SVM tiene un mayor coeficiente de determinación R^2 de 92, 73% y el ANN con un 90.64%, mientras tanto en algoritmos de segmentación de HSI con 95.23%, por otra parte, el umbral de Otsu con del 89.10%, K-means Clustering con 83.55%. por ende, los estudios indican que los índices de vegetación como REDSI, PRI, PRSSa, VARI y NDVI podrían ser utilizados para la clasificación de plagas y enfermedades, ya que tienen un mayor R^2 , siendo que, en las técnicas de segmentación, los algoritmos de clasificación de ANN y el SVN son los más usados, y en el algoritmo de segmentación el de mayor precisión es el HSI para mayor presión de la detección de las plagas y enfermedades en los cultivos.

Palabras claves: imágenes satelitales, procesamiento de imágenes, detección, índices de vegetación, plagas y enfermedades

Abstract

The aim of this research is to explain the methodological processes of satellite image processing for the detection of pests and diseases, as well as to review the main vegetation indices and describe the segmentation and classification algorithms used. To this end, information was extracted from articles, books, institutional pages, and theses, prioritizing an age of no more than 5 years. According to the total number of consultations, 68 documents have been selected as the main basis for this study, having as a result that the R² determination coefficient of the SR is the highest with 89.00%, while PRI, NDVI and GNDVI are the most used indexes in the research for the detection of pests and diseases with 70%, 50%, 50% respectively. Among the classification algorithms, SVM has a higher R² determination coefficient of 92.73% and ANN with 90.64%, while in HSI segmentation algorithms with 95.23%, on the other hand, Otsu threshold with 89.10%, K-means Clustering with 83.55%. Therefore, the studies indicate that vegetation indices such as REDSI, PRI, PRSSa, VARI and NDVI could be used for the classification of pests and diseases, since they have a higher R², being that, in the segmentation techniques, the classification algorithms of ANN and SVN are the most used, and in the segmentation algorithm the most accurate is the HSI for greater pressure of pest and disease detection in crops.

Keywords: satellite images, image processing, detection, vegetation indices, pests, and diseases

I. INTRODUCCION

El sector de agricultura juega un papel muy importante en el crecimiento de la economía del país. Las enfermedades y plagas en los cultivos son la principal fuente de pérdida del sustento de los agricultores. Organización de la Naciones Unidas para la Alimentación y la Agricultura (FAO), señala que se estima que entre el 20 y 40% de la producción agrícola a nivel mundial se pierde debido a las enfermedades y plagas, lo que genera que aumente los precios de los alimentos (FAO, 2015, párr. 4).

Las plagas y enfermedades en las plantas pueden acabar con el arduo trabajo de los agricultores y generar en ellos pérdidas significativas en el rendimiento del cultivo y sus ingresos. Los medios de subsistencia de aproximadamente uno 2 500 millones de personal a nivel mundial dependen de la agricultura y la FAO estima que a nivel de Latinoamérica y el caribe se generan pérdidas económicas de hasta 22 000 millones en daños entre el 2005 y 2015 (FAO, 2018, párr. 22).

El rendimiento potencial de cultivos agrícolas en todo el mundo viene siendo afectado por varios tipos de enfermedades y plagas como: insectos, falta de nutrientes, malezas, patógenos, entre otros. Esto genera la pérdida de la calidad de la producción del cultivo y la cantidad. Se estima que, si no hay un control de las plagas y malezas estas pueden reducir la producción de cultivos en un 18 y 32% respectivamente en todo el mundo; y la pérdida por enfermedades debido a bacterias, hongos y virus se estimó en 13% del potencial de producción (Oerke y Mahlein, 2012, párr. 2).

A partir del siglo XX al nivel mundial se ha incrementado la producción de los plaguicidas orgánicos sintéticos para poder contraatacar la propagación de plagas y enfermedades que pueden tener los cultivos. La producción y el uso de estos compuestos ha hecho que se incremente sustancias en los sedimentos, suelo, hidrosfera y atmosfera, provocando con ello una contaminación ambiental (García y Rodríguez, 2012, p. 1). Se estima que en la actualidad se aplica aproximadamente 3 mil millones de kilos de pesticidas en los cultivos en el mundo, pero aun así se pierde entre el 10 a 20 % de las cosechas (Porcuna, 2011, p .5).

Los métodos de detección directa (técnicas de laboratorio), establecidos como: Reacción en Cadena de la Polimerasa (PCR), Fluorescente in situ (FISH);

Ensayo inmunoabsorbente a enzimas (ELISA); Inmunofluoresc encia (IF), Citrometria de flujo (FCM) y Cromatografía de gases - espectrometría de masas (GC-MS) son los más utilizados actualmente para la detección de enfermedades de las plantas, sin embargo, estas son difíciles de operar y requieren de mucho tiempo para el análisis de datos, además, la mayoría de estos métodos no facilita la detección de enfermedades en tiempo real, lo que genera que no sean los más adecuados para pruebas de campo y sistemas de alerta temprana (Fang y Ramaraja, 2015, p. 553).

De acuerdo a la realidad problemática se planteó como **problema general**: ¿Cuáles son los procesos metodológicos de procesamiento de imagen para la detección de plagas y enfermedades en los cultivos?, a partir del problema general se plantea el **problema específico**: ¿Cuáles son los principales índices de vegetación utilizados para la detección de plagas y enfermedades en los cultivos?, ¿Cuáles son los algoritmos de segmentación y clasificación utilizados para la detección de plagas y enfermedades en los cultivos?

La presente revisión bibliográfica tiene como **objetivo general**: Explicar los procesos metodológicos de procesamiento de imágenes satelitales para la detección de plagas y enfermedades, y como **objetivo específico**: Revisar los principales índices de vegetación utilizados para la detección de plagas y enfermedades en los cultivos, Describir los algoritmos de segmentación y clasificación utilizados para la detección de plagas y enfermedades en los cultivos.

Esta revisión bibliográfica se **justifica debido a la escasa** información actualizada y en idioma español respecto a las técnicas de teledetección en la agricultura y el uso de imágenes para la detección de plagas y enfermedades en cultivos. Se pretende realizar un aporte teórico y actualizado referente a este tema que sirvas de apoyo a futuros trabajos de investigación.

II. MARCO TEORICO

En conformidad con lo argumentado anteriormente, se describe **los trabajos previos**, el cual proporciona el método para la detección de plagas y enfermedades en cultivos. Al respecto a continuación se presenta, en la tabla 01, estudios relacionados al tema.

Tabla 01. Estudios sobre detección de enfermedades y plagas de plantas usando técnicas de procesamiento de imágenes

Planta	Enfermedad y/o Plaga	Método utilizado	Referencia
Trigo	Oídio y roya	El estudio se hizo en un área de 6ha de trigo, se utilizaron 3 imágenes de alta resolución, se realizó el método de árbol de decisión para el análisis multitemporal, cálculo de NDVI y clasificación.	Franke y Menz (2007, pp.161-172)
Pinus nigra y pinus silvestre	Escolitidos	Se realizo el estudio en campo, con 34 muestras de árboles y la extracción de una imagen satelital, posteriormente se utilizó el programa ERDAS IMAGINE y la metodología de clasificación multiespectral con imágenes landsat	Blanco, Bonet y Eizaguirre (2009, pp. 264.275)
Remolacha	Cercospora beticola, Uromyces betaeo Erysiphe betae	Se realizo las tomas de fotos diariamente por 21 días para el análisis de las imágenes donde se usaron los métodos de clasificación como redes neuronales artificiales. (ANN), árboles de decisión, K-medias, k vecinos más cercanos y Las máquinas de vectores portuarios (SVM)	Rumpf et al (2010, pp .91-99)

Rosa	Cenicilla	Se tomaron 40 imágenes en total de 640x480 píxeles en las cuales 20 fueron a 50cm de distancia y las otras 20 a 10cm de distancia de las hojas con un medidor de luz CEM (DT-1309), se realizó el procesamiento de imágenes mediante la extracción de los colores de la región.	Velázquez et al. (2011.p 151-160)
Trigo	Fasarium	El estudio fue realizado en el laboratorio donde se cultivaron las plantas en un invernadero, fueron inoculadas artificialmente a la cepa f, donde se analizó el estudio de 104 imágenes hiperespectrales.	Bauriegel, Geyer, Schmint y Herppich (2010, pp. 304-312)
Granada	Tizón bacteriano (Xanthomonas axonopodis pv punicae)	Se utiliza 140 imágenes, en donde se utilizaron diferentes el procesamiento de imágenes y neuronales artificiales (ANN), realizando el filtrado y segmentado, para posteriormente realizar la clasificación de las texturas y colores.	Kulkarni Y Patil (2012, pp.3661 3664-)
Cebolla	Piel agria (Burkholderia Cepacia)	Se utiliza una cámara InGaAs para la clasificación de imagen hiperespectrales infrarroja de onda, se utilizó 320 imágenes de 256 píxeles en dos bandas.	Wang et al (2012.p.38-48)

Pepino, maíz y uva	Mildiu, mildiu polvoriento, antracnosis y tizón	Se realizo el estudio con una cámara casera con un sensor de imagen se utiliza Panasonic CCD color WV-CP234, Método de clasificación basado en procesamiento de imágenes	Tian, Wang y Zhou (2012, pp.162-171)
cítricos	huanglongbing	Las 12 imágenes hiperespectrales fue extraída en mediante un motor de ala fija donde la cámara utilizada fue AISA EAGLE VNIR, se realizó la clasificación de los índices de vegetación (NDVI, GNDNI, SAVI y NIR . se ´realizo el ´proceso de las imágenes en el programa MATLAB.	García et al., (2013, pp. 106-115)
Manzana y uva	Pudrición negra, Moho (uvas) y Apple Scab, Pudrición (Manzana)	Se usaron 92 imágenes en el sistema de aprendizaje, se realizó la implementación en las redes neurales y procesamiento de imágenes en sistema MATLAB, donde se clasifico las características de color, morfología y textura.	Jhuria, Kumar y Borse (2013, pp 581-586)
Flor de azúcar	babosas, caracoles, arañas rojas y minadoras de hojas	Se realizo la captura de 200 imágenes, con un robot aéreo Drone 2.0 (Desarrollado por Parrot, modelo 2.0) y, la cámara frontal, el RA cuenta con una cámara, posteriormente se procesaron en un software desarrollado en la plataforma Visual Express C#2010 utilizando el método de técnicas de procesamiento de imágenes	Cáceres, Amaya y Ramos (2015, pp 274 - 276)

Agave	el picudo del agave	Se utilizo una imagen de landsat 5 adquirida en 2 de abril del 2011, en donde la resolución del sensor es de 30m. se realizó el proceso de clasificación supervisada	Ramírez et al. (2017,pp.521-536)
Café	Roya Hemileia vastatrix	Se realizo el estudio de la plaga Roya en zonas cafeteras, obteniendo en total 11 imágenes multiespectrales del Satélite Landsat 8. Donde se aplica los métodos utilizados para la detección mediante el pre-procesamiento de imágenes e interpretación con clasificación supervisada.	Sánchez y Arguijo (2018, pp.309-317)
Brinjal	marchitez bacteriana (Pseudomonas solancearum)	Este estudio se realizó en campo, se utilizó una imagen de ASD Fieldspec Handheld 2 Espectro radiómetro., se procesó y analizo la imagen en View Spec Pro, para posterior realizar los cálculos de los diferentes índices de vegetación como (NDVI, NCARI, TVI, SIPI, PRI, NQPI, TCARI, NCPI, ZTM GM1 y GM2)	Kumar y Shibendu (2019, pp , 515- 520)
Cebolla	Tornado de cebolla	El área de estudio es de 2.85 hectáreas, se obtuvo una imagen de Sentinel 2 descargada en Science Hub de la Agencia Espacial Europea, asimismo se utilizó de Índices de vegetación (NDVI, GNDVI Y PSSRa) para la clasificación de los cultivos	Isip, Alberto y Biagtan (2019, pp.1-7)

El avance de la tecnología en la agricultura de precisión ha permitido generar escenarios más estables y rentables a los agricultores, proporcionado mantener un mejor control y gestión de los cultivos, el cual se da mediante el uso de cámaras y sensores que se ha implementado en satélites de diferentes tipos aéreos o terrestres (Caballero, et al.,2020, pp 453-454). Se emplea los sensores en la aplicación a la agricultura de precisión, permitiendo obtener los índices de área foliar, estrés hídrico, identificación de malezas e insectos, monitoreo en los cultivos y mapeo del suelo (Babankumar et al. ,2017 , pp. 383-407)

La plaga es toda aquella población de insectos que ataca a los cultivos, estos pueden ser puede artrópodo herbívoro, microbio patogenito o virus (Beber et al. ,2019, p. 2704). Sin embargo, se habla de plaga cuando un animal o microorganismo incrementa su densidad a niveles anómalos de tal manera que causa pérdidas económicas a los agricultores (Jimenez,2009, p. 13).

Asimismo, el termino enfermedad es el efecto de un organismo tales como: bacterias, virus y hongos; que atacan en el metabolismo de las plantas, causando en ellas clorosis, pudrición, alteraciones de crecimiento, entre otros (Villalva, 2012, p. 25). Los síntomas de las enfermedades se presentan en las hojas, frutos, tallo / tallo, raíces, etc. Principalmente los hongos son los responsables de generar una gran cantidad de daños y se caracterizan por marchitez, costras, revestimientos mohosos, herrumbre, manchas y tejido podrido (Pujari et al.,2015, p.1803).

Es por esa razón que la excesiva dependencia de los pesticidas y químicos ha llevado a la aparición de una resistencia generalizada, representando una grave amenaza para el control sostenible de una gran cantidad de plagas de insectos (Douglas ,2018, p. 638). En consecuencia, se tiene un costo económico y ambiental muy alto, mientras en la salud los abusos de los plaguicidas pueden provocar hasta la muerte por intoxicación y así mismo incrementar las probabilidades de generar enfermedades crónicas (Urea et al, 2014, p 79)

La teledetección es una técnica que permite adquirir información de objetos, fenómenos de la superficie terrestre o atmosfera a distancia; se da mediante el rastreo del espectro electromagnético que es emitido por los sensores a bordo, en

los vehículos aéreos o terrestres, las cuales registran los resultados en forma de imagen digital formada de píxeles (Balbontín et al. , 2016, p. 50).

El espectro electromagnético se expresa en termino de energía, mediante la función de la longitud de onda, generando una gama de bandas de longitud, en las cuales esta se agrupará dependiendo el tamaño de la onda, (Kumar y Dangi , 2016, p. 67-68) , como se muestra en la tabla 02 .En las plantas reflejan principlmente la energia de espectro visible y en infrarrojo, y estas brindan informacion del estado de la salud de las plantas (Perez,2018,p 8). A continuación, en la tabla 02 se detallarán los rangos de las ondas espectrales.

Tabla 02. Rango de las ondas espectrales

Banda	Características	Rango
Visible	Es percibida por los ojos, se presenta en la máxima radiación solar	Azul (0.4-0.5 um) Verde (0.5-0.6 um) Rojo (0.6-0.7 um)
Infrarrojo cercano	Pueden ser observadas mediante películas dotadas por emulsiones espaciales, aquí se puede diferenciar las masas vegetales y las concentraciones de humedad	0.7 a 1.3 um
Infrarrojo medio	Se mezclan la emisión de la superficie con la luz solar.	1.3 a 8 um
Infrarrojo lejano	Representa a la porción emisiva del espectro terrestre	8.14 um
Microondas	Es energía transparente a la corriente nubosa	1mm en adelante

Fuente : (Kumar Y Dangi , 2016, p. 67-68)

Al respecto las firmas espectrales, según Zuñiga (2018, p. 10) se entiende, como la representacion de la reflectancias en funcion a la longitud de onda, en el cual la firma va ser utilizado por algoritmos de clasifiacion para a etiquetar los pixeles de la imagen dependiendo el tipo de la cobertura (suelo desnudo o no vegetado, agua, vegetacion. Las firmas espectrales se pueden interpretar por medios de graficas como se observa en la figura 1, que representan la intensidad de la luz que es

reflejada de un objeto , y permite obtener informacion para la interpretacion de las imágenes obtenidas en los sensores remotos (Fajardo, 2018,p. 2) .

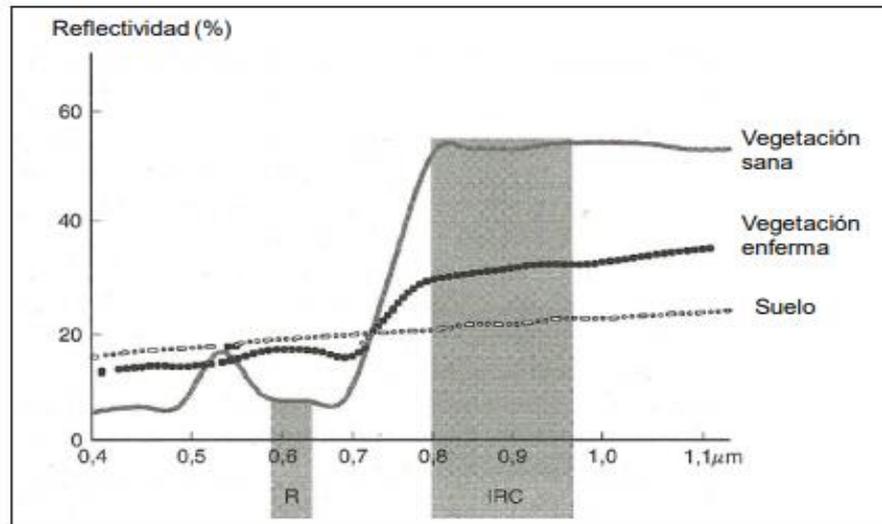


Figura 1. Firmas espectrales de la vegetación sana y enferma entre las bandas del visible e infrarrojo cercano. (RULLAN, 2015 pág. 9)

Las imágenes de satélite son producto obtenido mediante las capturas del sensor instalado en el interior de un satélite artificial, así mismo detecta la radiación electromagnética emitida o reflejada. Posteriormente el dato se emite a estaciones terrenas para visualización, procesamiento y análisis (Aguilar, 2014. p. 29-31).

Se tienden a clasificar las imágenes de satélite en 3 tipos: i) imagen pancromática (PAM) solo dispone de una sola banda espectral teniendo principalmente imagen a escala de grises, la ventaja es que posee una mayor resolución y con ello permite la detección de pequeños elementos en la superficie, mientras tanto las ii) imágenes multispectrales (MS) son las que contienen varios valores numéricos en cada píxel y cuenta con mayor cantidad de bandas en el sensor que permite obtener productos con mayor claridad y capacidad de análisis. Asimismo se tiene las iii) imágenes hiperespectrales, se caracteriza por contener mayor número de bandas, estas imágenes se usan cuando se requieren realizar una mejor identificación y clasificación de imágenes (Labrador et al. , 2012, p. 21).

Por otro lado los sensores de alta resolución son sistemas de percepción remota de diferentes resoluciones, en donde se puede obtener imágenes con frecuencia temporal , se pueden obtener dependiendo de los cuatro tipos de resolución: i)La resolución espacial; es el tamaño del píxel y es importante para la interpretación

de las imágenes , debido a que en ella se puede ver los detalles que ofrece en la imagen ii) La resolución espectral; es el que permite ver el número y ancho de las bandas espectrales que discrimina el sensor mediante la radiación electromagnética. Mientras que la iii) resolución radiométrica es la que expresa la perceptibilidad del sensor, en la que discrimina las pequeñas variaciones en la radiación estas se representan mediante el número de bits necesarios para que se pueda almacenar y finalmente la iv) resolución temporal; es la que indica el intervalo de tiempo entre las imágenes obtenidas, mediante la plataforma de la misma zona.(Moreno , 2018, pp. 23-24) (Diaz y Cervigon,2015, pag 13-15)

En la siguiente sesión se presentara los procesos metodológicos de procesamiento de imagen para la detección de plagas y enfermedades en cultivos. En la figura 2 se muestran el flujograma de los pasos

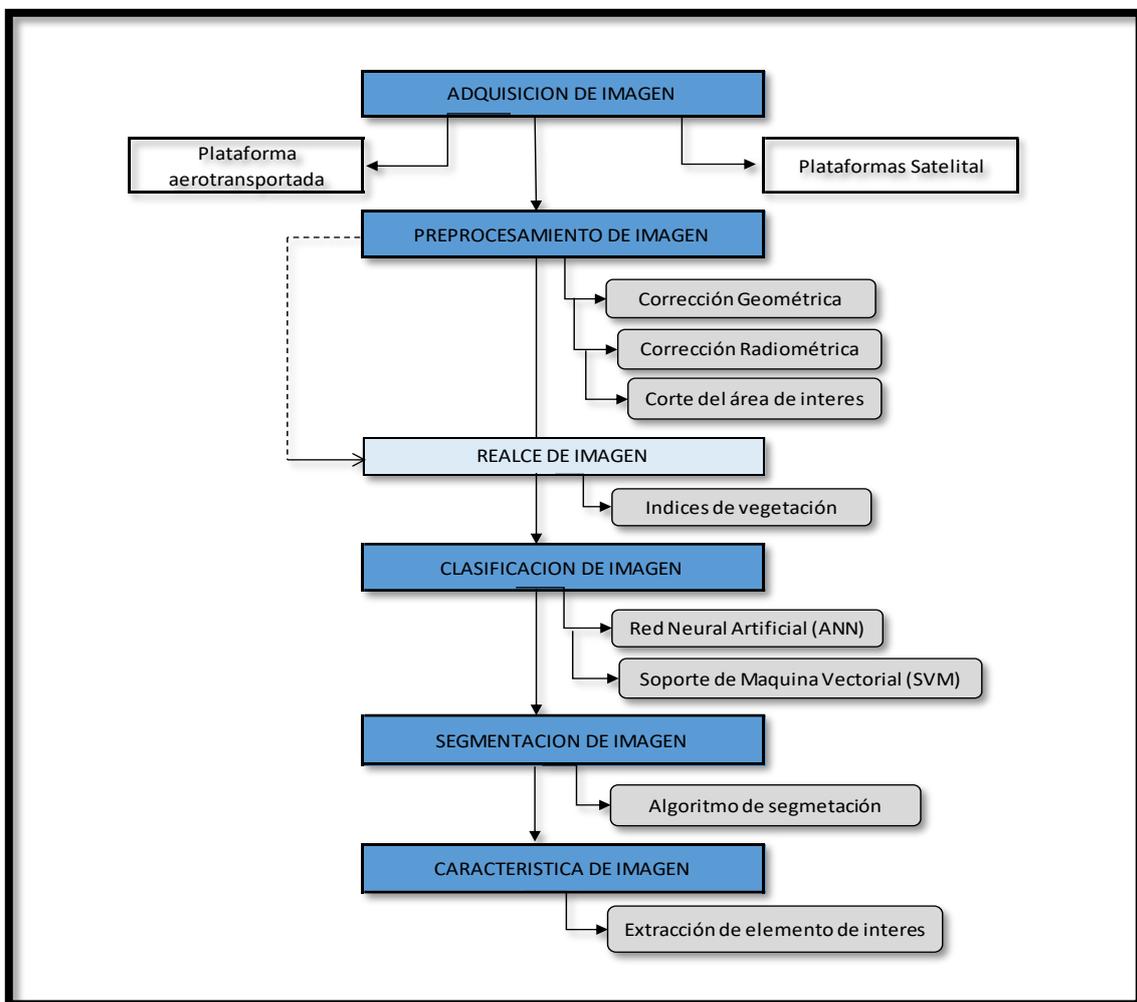


Figura 2. Procedimientos básicos para detección de enfermedades y plagas.

Adaptado de Sachin y Patil (2015)

El procesamiento de imágenes consta de cinco pasos, los cuales son: Adquisición de imagen, preprocesamiento de imagen, segmentación de imagen, extracción de características y clasificación de imagen; y se mostrara a continuación

En la primera fase, se realiza la adquisición de imagen, la cual se puede obtener mediante una cámara multiespectral adaptada a un dron o mediante la extracción de imágenes satelitales, mostradas a continuación:

El Primer paso, Adquisición de imagen mediante cámara; Hiary y Rahamneh (2011, p. 7) señalan que, en esta fase, la imagen de la hoja de la planta se captura a través de una cámara. Esa imagen está en color RGB (Rojo, verde y azul) y es convertida a escala de grises para un mayor proceso de segmentación. Donde a continuación se presenta en la imagen 3 donde se muestras la imagen en color RGB (rojo, verde y azul)

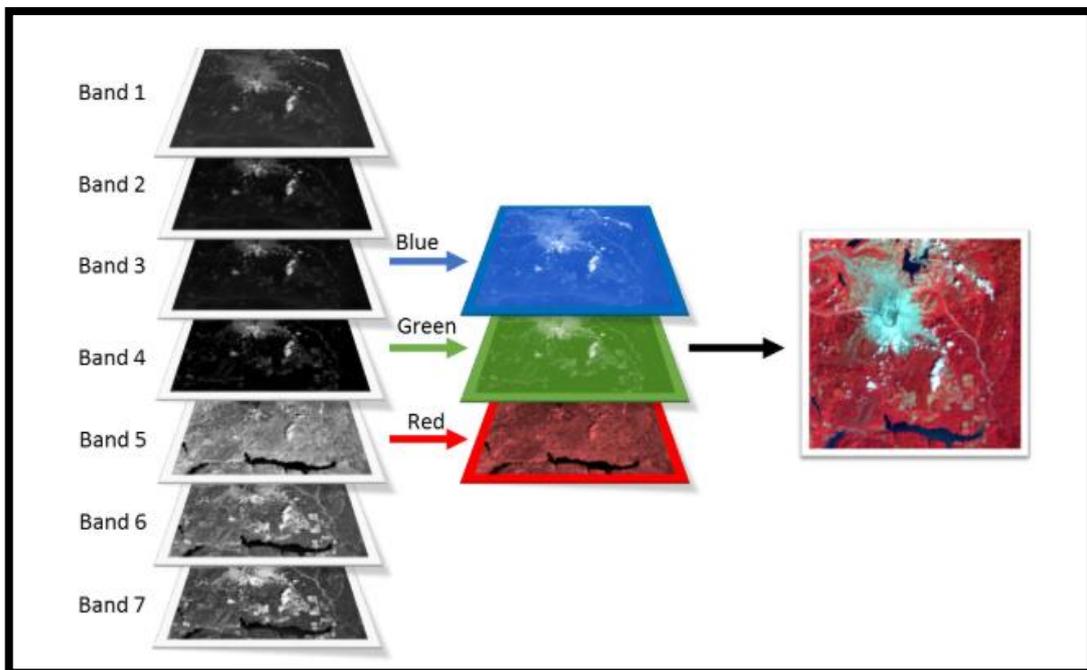


Figura 3. Imagen en color RGB (rojo, verde y azul)

Fuente: (GSP, 2014, párr. 2)

También se puede realizar la adquisición de imagen mediante satélites; en la actualidad hay varios satélites que nos permiten obtener imágenes como: landsat, modis, sentinel, entre otras. (Korhonen et al., 2017, párr. 3). Agroptima indica que sentinel-2 tiene como objetivo proporcionar datos multiespectrales con una frecuencia de 5 días a comparación de Landsat que proporciona datos con

frecuencia de 10 días. Las ventajas que tiene sentinel-2 con respecto a Landsat, es que sentinel-2 trabaja con mucha más resolución (10x10 m) y landsat tiene una resolución de (30x30 m), esto quiere decir que sentinel puede trabajar en zonas en la que hay una agricultura de menor escala y se puede hacer estudios en ellas (2017, párr. 8). Según Kumbula y Ismail (2019) mencionan que sentinel 2, es utilizado para monitoreo del estado de la vegetación (p. 49).

Las herramientas SIG (Sistemas de Información Geográfica) y los recursos web pueden ayudar a los agricultores a realizar un pronóstico del estado de sus cultivos mediante el uso de imágenes multiespectrales proporcionadas por satélites.

A continuación, en la tabla 03 se detallarán los sensores utilizados para el monitoreo de la vegetación.

Tabla 03. Sensores para el monitoreo de la vegetación.

Sensor	Plataforma	Rango espectral	N.º de bandas	Resol. (metros)	Anchura (km)	Lanzamiento
AVHRR	NOAA POES 6-19	VIS, NIR, MIR	5	1,100	2,400	1879
SEAWIFS	ORBVIEWS-2	VIS, NIR	8	1,100- 4,500	1,500- 2,800	1997
VEGETACION	PUNTO 4, 5	VIS, NIR, SWIR	4	1,100	2,200	1998
MODIS	EOS/ AQUA/TERRA	VIS, NIR, SWIR, TIR	36	250- 1,000	2,330	1999
MERIS	ENVISAT	VIS, NIR	15	300 - 1,200	1,150	2000

PROBA-V		VIS,		300	–		
	PROBA-V	NIR,	4	1,000		2,250	2014
		SWIR					
OLI		VIS,		30	–		
	LANDSAT	NIR,	11	100		705	2014
		SWIR					
SENTINEL 2		VIS,		10	–	60	
	CENTINEL A	NIR,	13			786	2015
		SWIR					

Fuente: Adaptado de (Rembold, et al, 2013, 1707)

VIS: reflectancia espectral Visible

NIR: reflectancia espectral del canal infrarrojo cercano

SWIR: reflectancia corregida atmosféricamente correspondiente al I rojo del visible

TIR: reflectancia espectral Onda Térmica

MIR: reflectancia espectral Infrarrojo medio

En la actualidad, existen varios sitios web para descargar imágenes satelitales gratuitas y a continuación se presentan algunas de las plataformas en la tabla 04.

Tabla 04. Principales sitios web para descargar imágenes satelitales gratuitas.

Satélite	Página web
LANDSAT 8	Glovis: https://glovis.usgs.gov/
	Earth Explorer: https://earthexplorer.usgs.gov/
	LandsatLookViewer: https://landlook.usgs.gov/viewer.html
SENTINEL 2	ESA: https://scihub.copernicus.eu/dhus/#/home
	Earth Explorer: https://earthexplorer.usgs.gov/
AQUA Y TERRA	SentinelToolbox: https://sentinel.esa.int/web/sentinel/toolboxes/sentinel-2

Fuente: (Ferreyra, 2016, p. 57-58)

En la siguiente fase se describen las dos técnicas de preprocesamiento que son mediante cámara e imágenes satelitales, las cuales se detallaran a continuación:

El Segundo paso, Preprocesamiento de imagen con cámara; para eliminar el ruido u objeto de la imagen se consideran diferentes técnicas de procesamiento. Primero se recorta la imagen en la región interesada, luego se utiliza el filtro de suavizado, el cual lleva a cabo el aumento del contraste de la imagen. En una imagen RGB (Rojo, Verde y azul), cada pixel representa 3 componentes: Rojo (R), verde (V) y azul (B), las imágenes RGB se convierten en imágenes a escala de grises usando la ecuación 1 (Gunes et al., 2015, párr. 4):

$$I = 0.299 (R) + 0.587 (G) + 0.114 (B) \dots\dots\dots (1)$$

Donde:

I: Intensidad, R: Banda roja, G: Banda verde, B: Banda azul

La finalidad de convertir la imagen RGB a escala de grises es para preservar el brillo del insecto en la imagen.

Se menciona que la razón principal por la que la representación en escala grises se utiliza a menudo para extraer descriptores en lugar de operar directamente con la imagen a color; es que la escala de grises simplifica al algoritmo y reduce los requisitos computacionales. (Kanan y Cottrell, 2012 párr. 3).

El Preprocesamiento de las imágenes satelitales es el proceso por el cual se tiene datos crudos y se realizará manipulación para el mejoramiento y extracción de la información ,mayormente las imágenes extraídas presentan una serie de alteraciones radiométricas y geométricas debidos a diferentes factores que se presenta por las condiciones climatológicas y del terreno, se empieza por realizar las correcciones radiométricas y geométricas para mejorar la calidad de los pixeles (Galindo y García , 2014 , p.63) . La Corrección geométrica es la primera parte del proceso a realizar en la mejora de la calidad de los pixeles en la imagen satelital, brindando a cada pixel o un grupo las coordenadas estándar (UTM, Lambert, coordenadas geográficas) correspondiente en las cuales permiten proporcionar las información de la zona y la corrección radiométrica permite realizar las correcciones de los errores emitidos por la irregularidad en el sensor o atmosfera,

para tener resultados más precisos y permite comparar con mayor facilidad las imágenes recogidas por distintos sensores (Hantson . et al,2011, pp. 51-61)

Los Índices de vegetación para Candiago et al. (2015, p.4428-4429) son combinaciones de varias bandas espectrales que presentan la información sobre el vigor de la vegetación y las propiedades del cultivo, en la cuales reflectancia es baja en las regiones azules y rojas en el espectro, mientras el punto más alto en el rango verde. Zhanget indica que los índices de vegetación se utilizan ampliamente para la detección y seguimiento de enfermedades y plagas, debido a que estos pueden enfatizar algunas propiedades biofísicas de las plantas, dado que la variación del contenido de pigmento vegetal puede inducir una clara respuesta espectral (2019, p. 6). Las principales aplicaciones para la detección remota de la vegetación se centran en la región ultravioleta (UV), los espectros visibles (se componen en: longitud de onda roja (620-750 nm), verde (495-570 nm) y azul (450-495 nm); y la banda infrarroja cercana y media. (Hazli y Muhammad, 2016, párr. 1)

Se presenta en la tabla 5, la lista de los índices de vegetación utilizados para detección de enfermedades y plagas:

Tabla 05. Índices de vegetación utilizados en estudios para detección de enfermedades y plagas.

Índice de vegetación	de Formula	Referencia
Índice de vegetación de Diferencia Normalizada (NDVI)	$NDVI = \frac{\varphi_{NIR} - \varphi_{RED}}{\varphi_{NIR} + \varphi_{RED}}$	Sánchez y Arguijo (2018, p. 315)
Índice de estrés por humedad (MSI)	$MSI = \frac{SWIR}{NIR}$	Rullan (2015, p. 104)
Índice de vegetación ajustado al suelo (SAVI)	$SAVI = \left(\frac{\varphi_{NIR} - \varphi_{RED}}{\varphi_{NIR} + \varphi_{RED} + L} \right) * (I + L)$	Candiago, Remondino, Giglio, Dubbini y Gattelli (2014, p. 4029)

Índice de Vegetación Normalizado Verde (GNDVI)	$GNDVI = \frac{\varphi_{NIR} - \varphi_{GREEN}}{\varphi_{NIR} + \varphi_{GREEN}}$	Candiago, Remondino, Giglio, Dubbini y Gattelli (2014, p. 4029)
Índice de Reflectancia Fotoquímica (PRI)	$PRI = \frac{\varphi_{R531nm} - \varphi_{R570nm}}{\varphi_{R531nm} + \varphi_{R570nm}}$	Prabrakar y Venkateswarlu (2011, p. 192)
Índice de estrés vegetativo de borde rojo (RVSI)	$RSVI = \frac{\varphi_{R714nm} - \varphi_{R752nm}}{2 + \varphi_{R733nm}}$	Luo y Huang (2013, p. 691)
Clorofila modificada (a y b) absorción en reflectancia índice (MCARI)	$MCARI = [(R_{700nm} - R_{670nm}) - 0.2(R_{700nm} - R_{550})] \times R_{700nm} / R_{670nm}$	Zhang y Yuan (2012, p. 1482)
Visible atmosféricamente índice de resistencia (VARI)	$VARI = \frac{\varphi_{GREEN} - \varphi_{RED}}{\varphi_{GREEN} + \varphi_{RED} - \varphi_{BLUE}}$	Naidu y Perry (2009, p. 41)
	Blue: 470-490nm Green: 530-570nm	
Índice de agua (WI)	$WI = R_{900nm} / R_{970nm}$	Naidu y Perry (2009, p. 41)

NIR: reflectancia espectral del canal infrarrojo cercano; *RED*: Banda visible roja; *RE1*: Banda borde rojo de vegetación; *L*: Constante de compensación promedio, 0.5; *GREEN*: Banda visible verde; *BLUE*: Banda visible azul; *R*: Reflectancia; *SWIR*: reflectancia espectral del canal infrarrojo medio.

El tercer paso, es la clasificación de imagen, el proceso de reconocimiento consta de 2 fases; red neural artificial y máquina de vector de soporte que se detallan a continuación: Red neural artificial (ANN): Después de realizar la extracción de características de las imágenes que se hallan en la base de datos, se clasifican

mediante el uso de red neural. Se detallan que los ANN son modelos computacionales y contienen una gran cantidad de elementos de procesamiento los cuales se llaman neuronas, la salida de las neuronas es la función de la suma ponderada de las entradas (Omrani et al., 2014, p. 4). Por otro lado, Anand y Ashwin (2012) un ANN es configurado para identificar una regla de acuerdo con las características seleccionadas, como un patrón de reconocimiento de datos, a través de un proceso de aprendizaje. (p. 3662).

La figura 4, muestra el esquema de Red Neural ANN, el cual consta de 3 capas, la cual, en la primera capa se ingresa todos los pixeles de la imagen, para luego pasar a la capa oculta donde disminuye el número de pixel para aumentar la calidad de la imagen y clasificar los objetos según el número de clases, y por último salen la imagen ya clasificada por la capa de salida (Sachin y Patil, 2015, p. 770).

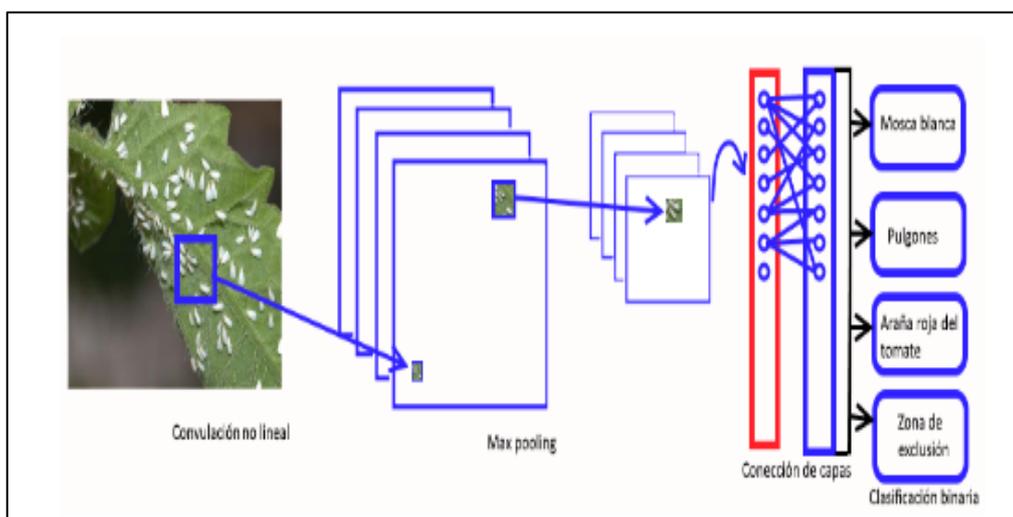


Figura 4. Esquema de Red Neural ANN

Fuente: (Berra, Pérez y Cuautle, 2019, p. 25)

Por otro lado, el Soporte de máquinas vectoriales (SVM): El SVM lo utilizan para proporcionar una clasificación supervisada, no supervisada y para calcular modelos lineales y no lineales (Behma, et al, 2014, párr. 1). En el campo de clasificación de enfermedades de plantas, las máquinas de vectores de soporte son ampliamente utilizados, y utilizan el sensor hiperespectrales para determinar el área de los cultivos enfermo y del no enfermo en las hojas de remolacha azucarera (Rumpf et al., 2010, p. 93).

El SVM (Soporte de maquina Vectorial) presenta una característica principal, es que minimiza el error de entrenamiento observado, es decir intenta minimizar el límite de error para lograr un alcance integral. Behmam et al. (2014, p.15). Indican que SVR es potencialmente una alternativa prometedora a los modelos de predicción existentes.

En la figura 5, se muestra la clasificación mediante Maquina de soporte vectorial, el cual realiza una clasificación no supervisada de las clases según sus mismas características (plantas infectadas de las no infectadas) y las separa por clases mediante la línea vectorial.

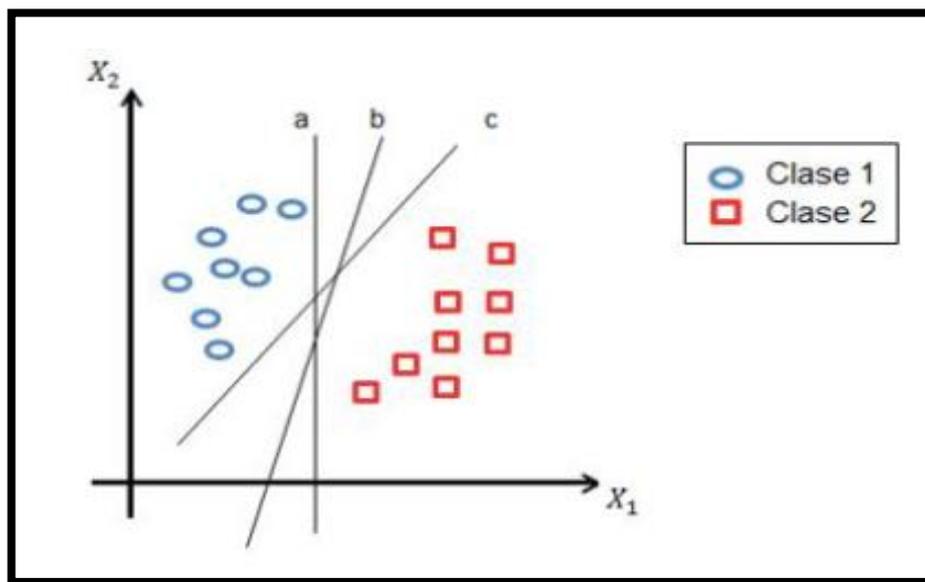


Figura 5. Clasificación por Soporte de máquinas vectoriales.

Fuente: (Riaño, Acosta y Leal, 2016, p.56)

En algunos estudios, se aplica más de un algoritmo de clasificación. García, et al., (2013, p.114) demostraron que SVM es superior al algoritmo de Análisis discriminante lineal y cuadrático (LDA y QDA; 75% de precisión y menos) para la detección de enfermedad del reverdecimiento de los cítricos. La mayoría de los estudios, SVM y ANN alcanzan una mayor precisión (Behmann, et al., 2014, p. 123). Asimismo, Lowe, et al. (2017), indican que los Red Neural convencional (CNN) se basan en campos retinianos en cualquiera sea el enfoque, el aprendizaje profundo lleva más tiempo para entrenar y la arquitectura es más compleja (p- 6). En el pasado se ha utilizado varios clasificadores de investigadores como el Vecino k-más cercano (KNN), Red Neural de Propagacion hacia atrás (BPNN), el más

utilizado se encuentra que el clasificador es SVM, aunque cada clasificador tiene su ventaja y desventaja. SVM es más fácil de usar (Kiran y Ujwalla, 2014, p.15).

El cuarto paso, es la Segmentación de imagen, Sachin y Patil (2015, p. 769), segmentación de imagen significa la división de la imagen en varias partes con las mismas características o que tengan alguna similitud. La segmentación se puede hacer usando varios métodos: i) Algoritmo de umbral de Otsu ii) Algoritmo K-means agrupamiento y iii) Intensidad de Saturación de Color (HSI).

La segmentación de imagen es un proceso utilizado para simplificar la representación de una imagen en algo que es más significativo y fácil de analizar (p. 13). La segmentación es también un enfoque fundamental del procesamiento de imágenes digitales, el cual indica que hay varias técnicas para segmentar una imagen y son las siguientes (Kiran y Ujwalla, 2014, p.13):

- (1) Basado en la región; los pixeles relacionados con un objeto se agrupan.
- (2) Basado en el borde; técnica de detección de borde. Hay varias técnicas a saber (registro, gradiente, astuto, Sobel, laplaciano, Robert, entre otras)
- (3) Basado en el umbral; es la forma más fácil de segmentar.
- (4) Clustering basado en funciones; los pixeles de la imagen en color se agrupan para la segmentación utilizando un sistema no supervisado.

Sin embargo, Huddar et al. (2012) presentan un nuevo algoritmo de segmentación basado en el procesamiento de imágenes para identificar y detectar plagas en las hojas (p. 3). El algoritmo de diferencia relativa en intensidades de píxel (RDI); fue diseñado para el programa MATLAB 7.1 y la presión obtenida es del 96% que se probó para varias moscas blancas.

Mencionan Phadikar y Sil (2008, p. 420), que las imágenes se mejoran aumentando el brillo y contraste para luego transformarla en el Método de Intensidad de saturación de color (HIS) y el Método de umbral, que permite facilitar la identificación de las plantas infectadas que se mostraran en la (figura 5) con la ecuación de 1 a 3 siguientes (Nazrul, et al., 2015, p. 627):

$$H = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G)+(R-B)]}{\sqrt{[(R-B)^2+(R-B)(G-B)]^{\frac{1}{2}}}} \right\} \dots \dots \dots (1)$$

$$S = \frac{3}{(R+G+B)} [\min(R, G, B)] \dots\dots\dots (2)$$

$$I = \frac{(R+G+B)}{3} \dots\dots\dots (3)$$

Donde:

H: color; S: Saturación; I: Intensidad; R: Banda visible roja; G: Banda visible verde y B: Banda visible azul.

En la figura 6. Se muestra la hoja del cultivo de arroz infectada (a), el cual se le realiza el proceso de segmentación mediante el modelo de saturación y el método de umbral para poder identificar la parte infectada de la no infectada de la plata, como se observa en la imagen (b), que es la imagen segmentada de la hoja y como se muestra se observa como una mancha de color negra y tiene las mismas características de la imagen (a).

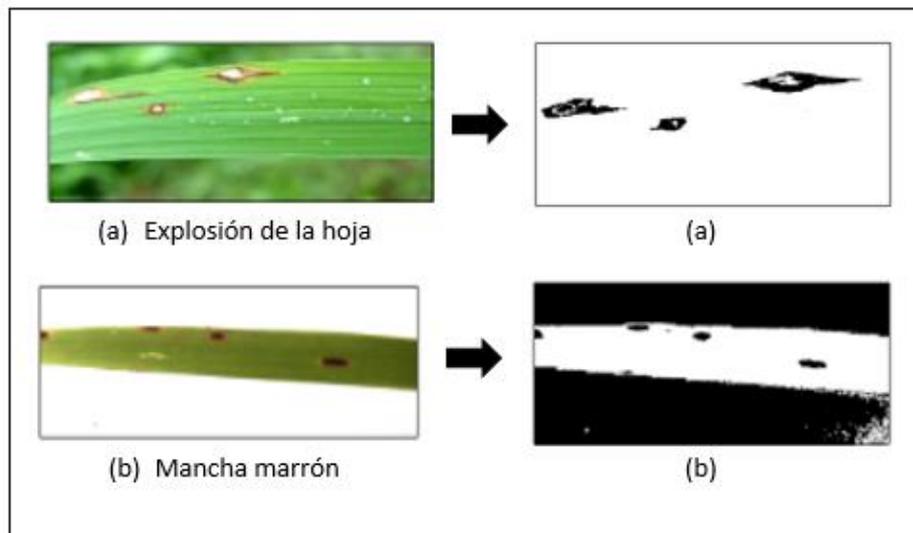


Figura 6. Imágenes originales e imágenes segmentadas de la hoja de arroz infectada

FUENTE: Phadikar y Sil (2008, p. 420)

El quinto paso, es la extracción de característica; Shivani y Dhanashri (2016, p. 2) señala que la extracción de característica de forma se realiza después de la fase de segmentación para poder obtener el límite del insecto, superficie y textura, aplicar agrupación, para posteriormente el proceso de extracción de características llamado “Coincidencia de color o el método CCM”, es utilizado para detectar

diferentes características de enfermedades como: moho algodonero y moho ceniciento. Sandhu y Kaur indican que existen varios métodos de extracción que pueden emplearse para desarrollar el sistema, como: la matriz de ocurrencia de nivel de grises (GLCM), Método de ocurrencia de color, matriz de independencia espacial de nivel de gris y extracción de características basadas en histogramas (2019, p. 37).

La extracción de característica juega un rol importante para la identificación de un objeto, en muchas aplicaciones de la función de procesamiento de imágenes se utiliza la extracción de 3 vectores: color, textura y morfología, la cual se pueden utilizar en la detección de enfermedades (Jhuria, 2013, párr. 1). A partir de estos vectores la morfología da un 90% de resultados correctos que los otros dos vectores.

III. MÉTODO

3.1. Tipo y diseño de investigación

El tipo de investigación es básico. Al respecto, Tam et al. mencionan que la investigación básica tiene como objetivo brindar mejoras para el conocimiento, en donde más que generar resultados o tecnologías, permiten dar beneficios a la sociedad en el futuro (2008, pág. 146), también es conocido como investigación pura debido a que se realiza con el propósito de incrementar conocimientos teóricos para el avance de la ciencia, asimismo permite tener el conocimiento de la realidad o la verificación de las hipótesis (Ander, 1995, p.15).

El diseño de investigación a utilizar es cualitativo narrativo de tópicos, el cual, Creswell (2005), señala que el diseño narrativo de tópicos, en diferentes casos es un esquema de investigación, pero también es una forma de intervención, ya que el contar una historia ayuda a procesar cuestiones que no estaban claras. (p. 23)

3.2. Categorías, subcategorías y matriz de categorización apriorística

En la tabla 06 se mostrarán los objetivos y problemas específicos, en esta se detallarán las categorías; que denotan el tema en sí y las subcategorías.

Tabla 06. Categoría, Subcategoría y matriz de categorización apriorística.

Objetivos Específicos	Problemas Específicos	Categorías	Subcategorías	Unidad de análisis
Revisar los principales índices de vegetación utilizados para la detección de plagas y enfermedades en los cultivos	¿Cuáles son los principales índices de vegetación utilizados para la detección de plagas y enfermedades en los cultivos?	Índices de vegetación	NDVI	Blackburn, G. A ,1998, p. 665
			SAVI	Candiago, et al, 2014, p. 4029
			GNDVI	Delegido, et al, (2011, p. 7066
			RVSI	Feng, et al. 2017, p. 1-5
			PRI	Hallik et al. 2017, parr. 13
			MCARI	Abdulridha, et al. 2018, p. 2019
			MSI	Huang y Lamb, 2007, p. 187
			SR	Isip et al., 2019, párr.1
			REDSI- Re1	Mirik, et al. 2012, p. 510
			REDSI- Re3	Naidu y Perry (2009, p. 41)
			PSSRa	Prabhakar, et al., 2011, p. 194
			WI	Rullan, 2015, p. 104 Sánchez y Arguijo ,2018, p. 315, Yuan y Zhang, 2017
			VARI	Zhang y Yuan 2012, p. 1482

<p>Describir los algoritmos de segmentación y extracción de características utilizados para la detección de plagas y enfermedades en los cultivos.</p>	<p>¿Cuáles son los algoritmos de segmentación y clasificación utilizados para la detección de plagas y enfermedades en los cultivos?</p>	<p>Algoritmos de segmentación</p>	<p>Algoritmo de Umbral de Otsu</p>	<p>Bhange y Hingolowala, 2015, pp 280-288</p>
			<p>Algoritmo K means clustering</p>	<p>Caballero, et al.2015, pp 217-222 Cáceres, et el.,2015, pp 274 -276</p>
			<p>Intensidad de Saturación de Color (HIS)</p>	<p>Castrillon, et al. 2017, pp 7-19 García et al., 2013, pp. 106-115 Gwan, et al., 2009, p. 8</p>
		<p>Algoritmos de clasificación</p>	<p>Red neural artificial (ANN)</p>	<p>Kulkarni et al. ,2012, pp 3661-3664 Kuricheti y Supriya, 2019, p.548</p>
			<p>Soporte de máquinas vectoriales (SVM)</p>	<p>Marcial, M.2017, pp 1-101 Pawan, Warne Y Ganorkar, 2015, P. 429 Pujari, et al., 2015, p. 1806 Pydipati, Burks y Lee, 2005, p. 2013; Kuricheti y Supriya, 2019 p. 546 Rumpf, et al. ,2010, pp .91-99 Singh y Misra, 2017 Wang, et al, 2012.p.38-48 Wang, Jia Y Zhou, 2019, parr. 1</p>

Fuente: Elaboración propia

3.3. Escenario de estudio

Este estudio no tiene un escenario definido por tratarse de una revisión bibliográfica de diversos artículos científicos, internacionales orientados a la agricultura y el manejo de los sistemas de teledetección, para la detección de plagas y enfermedades en los cultivos.

3.4. Participantes

Para esta revisión se obtuvo información, tales como: artículos de revistas indexadas, libros, capítulos de libro, investigaciones de institutos de estadísticos públicos e investigaciones de agricultura y teledetección. Las fuentes utilizadas fueron: Sciece direct, Research Article, Spacial Information Research, INRES, EBSCO, etc. Se tomaron más de 100 investigaciones y se hizo la selección de investigaciones que se asemejan a nuestro tema de investigación.

3.5. Técnica e instrumentos de recolección de datos

Las técnicas de recolección de datos de una investigación cualitativa se agrupan en 3 principales categorías: Observación directa, entrevistas y uso de documentos (Corbetta, 2007, p. 302). Este estudio de revisión se basa en el uso de documentos, que plantea la técnica documental para realizar la recolección de información en Investigaciones Cualitativas, ya que es vital conocer los documentos de diversos autores, que han generado y continúan generando. (Núñez, 2016, párr. 47).

Para este aporte se realizó una ficha de análisis de contenido, el cual servirá para la recolección de información primordial y necesaria para un trabajo de investigación, esa ficha se encontrará en el Anexo 1.

3.6. Procedimientos

Esta Revisión bibliográfica comienza con la idea para luego el planteamiento de la pregunta específica que determinará los criterios y palabras claves que serán utilizados en la búsqueda de información como : artículos científico, sesión de libro, entre otros., que será útiles para responder dicha pregunta.

Una vez adquirida la información, se deben seleccionar los artículos, y una vez seleccionadas se deben obtener los datos necesarios, para luego realizar el

análisis de la información para luego la redacción del trabajo final de investigación (Figura 7).

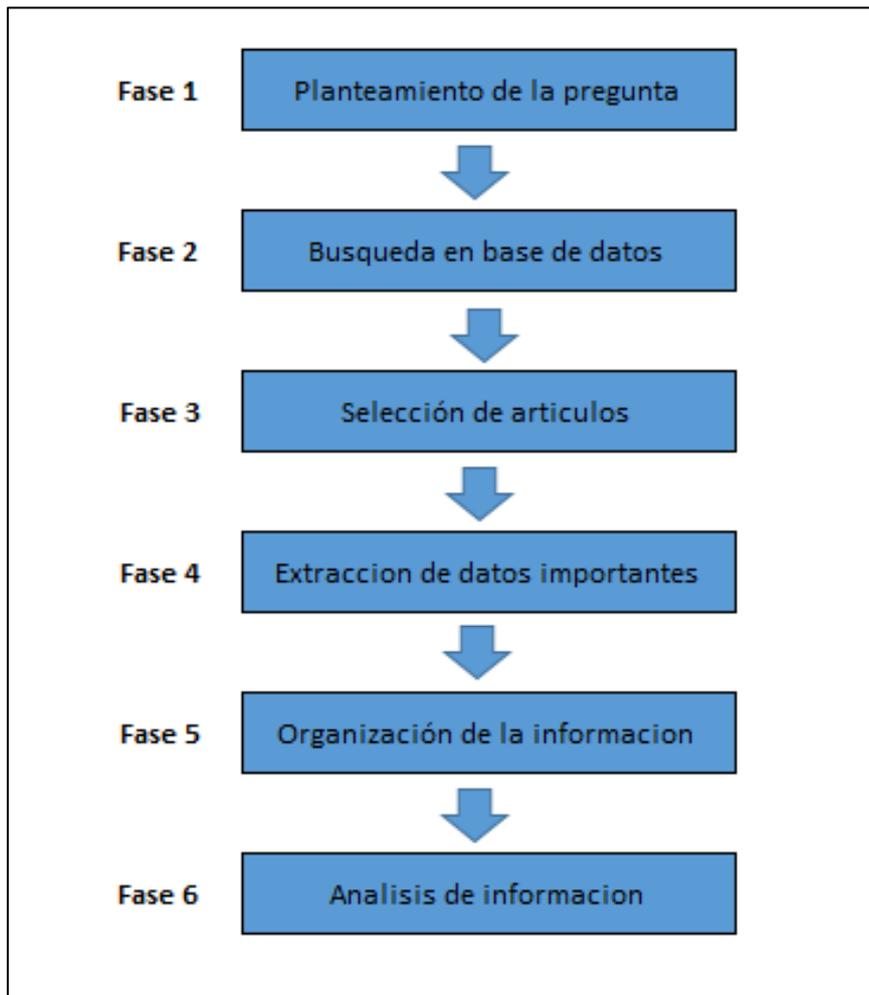


Figura 7. Proceso de elaboración de una revisión bibliográfica.

Fuente: Adaptado de (Moreno, et al.,2018, párr. 12)

Resulta conveniente el uso de un diagrama de flujo para mostrar el proceso de selección de artículos científicos, en el cual se detallará desde el número inicial de artículos hasta el final de estudios elegidos (Figura 8).

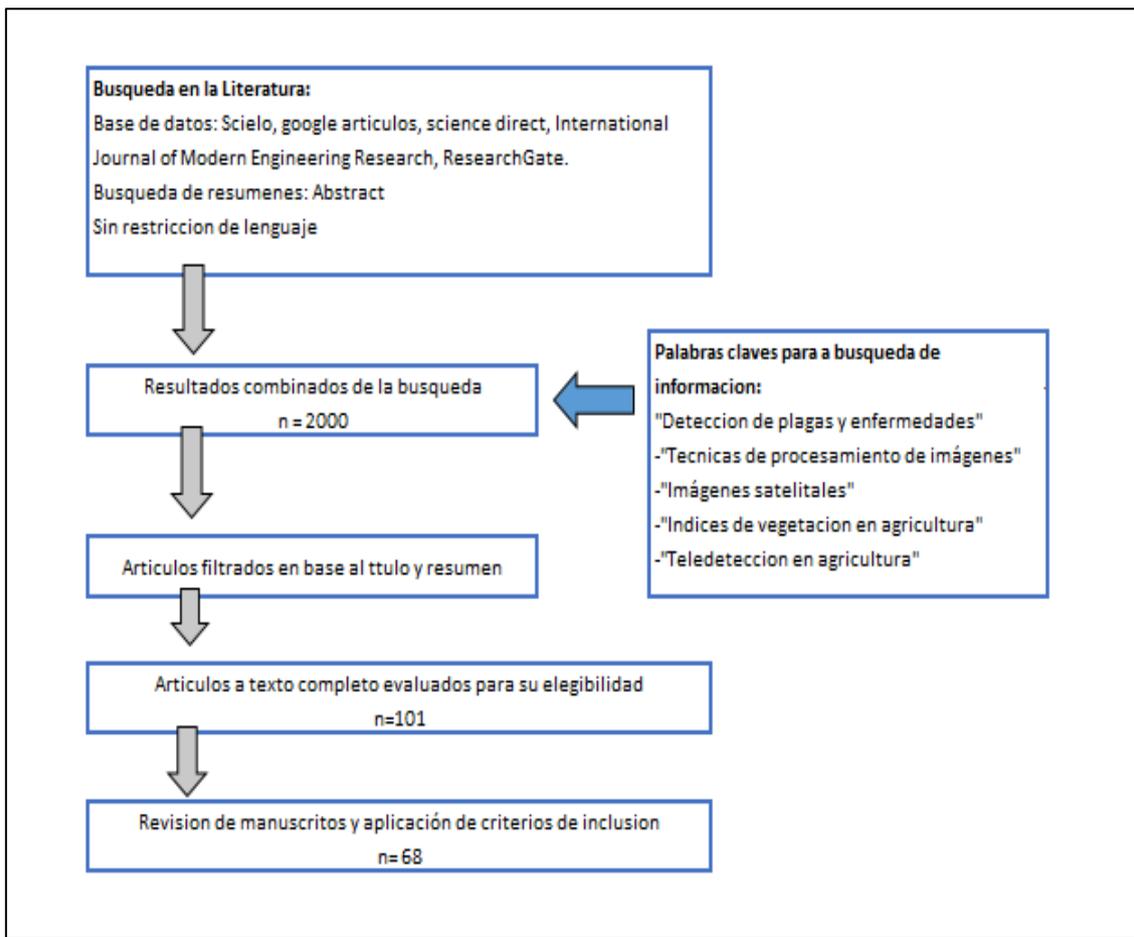


Figura 8. Diagrama de flujo de selección de artículo.

Fuente: (Moreno, et al., 2018, párr. 12)

Para la búsqueda de información se utilizó palabras claves en inglés y español tales como: Detección de enfermedades y plagas en cultivos, uso de imágenes satelitales, agricultura de precisión. Se seleccionó artículos científicos, capítulo de libros, revistas anexadas, páginas institucionales, entre otros; y estos fueron extraídos de la base de datos de: Scielo, Sciece Direct, EBSCO, Fao, International Journal of Modem Engineering Research. Se consideró los artículos con una antigüedad de 5 años. En la tabla 07 se presenta el resumen del criterio de búsqueda de información.

Tabla 07. Resumen de criterios de búsqueda de información.

Tipo de documento	Documentos referidos a	Nº de documentos revisados	Palabras claves	Criterios de inclusión	Criterio de exclusión
Artículos científicos	Detección de plagas y enfermedades en cultivos / Índices de vegetación para detectar enfermedades de las platas	68	“Detección de plagas y enfermedades en cultivos”, “Teledetección en agricultura”, “Técnicas de procesamiento de imágenes”, “Índices de vegetación”	-Últimos 6 años -Metodología de trabajo -Información clara -Resultados	- Mayor de 6 años de antigüedad - Resultados -Información incompleta -Información poco entendible
Capítulos de libros	Uso de imágenes multiespectrales para el manejo de plagas	2	“Manejo de plagas”, “Imágenes multiespectrales”	-Últimos 5 años -Información de interés	- Mayor a 5 años - Información innecesaria
Paginas institucionales	FAO/Geospacial/MIN AGRI	12	“Plagas y enfermedades en cultivos”, “imágenes satelitales”	-Últimos 5 años - Información relevantes	- Falta de información - Mayor a 5 años de antigüedad

Tesis	Identificación de plagas en el cultivo de olivo / Aplicación de la teledetección en agricultura	2	“Detección de enfermedades de las hojas”, “Teledetección en agricultura”	- Información necesaria -últimos 5 años -Información profesional	- Mayor a 5 años de antigüedad - Falta de datos o información
Libros	Satélites de teledetección/ Teledetección y Medio Ambiente	2	“Agricultura de precisión”, “Teledetección”	-Información relevante y de últimos 5 años.	- Mayor a 5 años de antigüedad

Fuente: Elaboración propia

3.7. Rigor Científico

Consistencia o dependencia lógica; se refiere al grado en que diferentes investigadores recopilen datos semejantes en el campo y realicen los mismos análisis y generen resultados equivalentes. En otras palabras, se relaciona con la estabilidad de datos y resultados, no a la réplica del estudio de investigación (Elizalde, 2017, párr. 2).

Credibilidad; este criterio resulta cuando un investigador, a través, de observaciones y discusiones, recoge información que hace que los informantes reconozcas esta como una verdadera aproximación sobre lo que ellos piensan y sienten (Castillo y Vásquez, 2003, pg. 165).

Transferibilidad; también llamada aplicabilidad de resultados trata de transferir los resultados de la investigación a otros trabajos de investigación. La transferibilidad se refiere a que los fenómenos estudiados estén vinculados a las situaciones de contexto y a las personas participantes de la investigación, es decir, los resultados de la investigación cualitativa no son generalizables, sino transferibles de acuerdo con el contexto en que se apliquen. (Noreña, et al., 2012, p. 267).

Confirmabilidad; para Pla (1999), la confirmabilidad hace referencia a la neutralidad del investigador. Los procedimientos irán orientados a la recogida de registros concretos y mecánica de la información (grabaciones). Esto permitirá analizar los resultados para luego llegar a conclusiones siempre y cuando se tengan perspectivas similares (pp. 297-298).

3.8. Método de análisis de información

Izaguirre, Rivera y Mustelier (2010), al investigar buscamos y seleccionamos bibliografías para el análisis y descripción de toda la información, sobre el tema que estamos investigando con el objetivo de conocer los antecedentes del tema a investigar, desarrollar el contexto conceptual y obtener información sobre el método de investigación de revisiones bibliográficas (pp. 6-7)

3.9. Aspectos éticos

Esta investigación fue el resultado de la compilación de datos obtenido de diferentes autores sobre detección de plagas y enfermedades en los cultivos

mediante imágenes satelitales. Así mismo, se extrajo información complementaria que es apoyada por citas bibliográficas citas apropiadamente siguiendo el manual de referencias Estilo ISO 690 - 690-2 fondo editorial UCV, así dando conformidad artículo 15 del Código de Ética de la Investigación de la UCV, aprobado con la resolución de Consejo Universitario N°. 0126-2017/UCV del 23 de mayo de 2017. Se respetó la propiedad intelectual de los autores utilizados que aportan su conocimiento, investigación y experiencias en sus artículos científicos, libros, capítulos de libros, revistas, entre otros.

IV. RESULTADOS Y DISCUSION

En la tabla 8, se presentan los resultados de diferentes estudios donde se utilizaron índices de vegetación para la detección de plagas y enfermedades en las plantas, se extrajo el coeficiente de determinación de cada índice de vegetación (NDVI, PSSRa, MCARI, PRI, SAVI, MSI GNDVI, RVSI, WI, VARI, REDSI Y RS).

Tabla 08. Índices de vegetación y coeficiente de determinación R²

Referencias	Planta	Plagas y/o enfermedades	Índices de vegetación	Precisión R ²
Isip et al., 2019, párr.1	Cebolla	Tornado de cebolla	NDVI	78.60%
			GNDVI	83.30%
			PSSRa	81.00%
Srivastava, et al., Kimothi, 2019	Brinjal	Bacteriana de la marchitez	MCARI	90.00%
			PRI	90.00%
Huang y Lamb, 2007, p. 187	Trigo de invierno	Oxido amarillo	PRI	97.00%
Rullan, 2015, p. 104	Coniforas	Defoliadores, Carpofagos	SAVI	70.30%
			MSI	71.40%
Prabhakar, et al., 2011, p. 194	Algodón	Saltahojas (Cicadellidae)	PRI	80.20%
			GNDVI	75.40%
			NDVI	78.80%
			MCARI	47.10%
Luo y Huang 2013, p. 694	Trigo de invierno	Afidios	GNDVI	50.00%
			RVSI	61.00%
Zhang y Yuan 2012, p. 1482	Trigo de invierno	Mildiu polvoriento	MCARI	62.00%
			RVSI	50.00%
			PRI	50.00%
Naidu y Perry, 2009, p. 41	Uva	Virus-3 del enrollamiento de la vid	RVSI	72.00%
			PRI	75.00%
			WI	62.00%
Mirik, et al., 2012, p. 510	Trigo	Pulgon de trigo ruso	NDVI	89.00%
			GNDVI	88.00%

Yuan y Zhang, 2017	Trigo	Roya amarilla	GNDVI	71.00%
			VARI	82.00%
Feng, et al., 2017, p. 1-5	Trigo de invierno	Moho polvoriento	PRI	90.00%
Zheng, et al., 2018, p. 15	Trigo de invierno	Roya amarilla	VARI	79.60%
			NDVI	78.80%
			REDSI-Re1	84.10%
			REDSI-Re3	85.20%
Hallik et al., 2017, parr. 13 Abdulridha, et al., 2018, p. 2019	Laurel	Marchitamiento del laurel	SR	90%
			PRI	94.00%
			NDVI	77.00%
			WI	85.00%

Fuente: Elaboración propia

SR (Índices de Relación simple) VARI (Índice de resistencia atmosféricamente visible)

En la tabla 9, se extrajo el análisis de regresión para evaluar la capacidad de los índices de vegetación en la estimación de la detección de plagas y enfermedades, en el cual se muestra los resultados del análisis de correlación de los índices de vegetación de varios estudios. El coeficiente de determinación (R^2), muestra que el SR, PRI, VARI y NDVI tiene una mayor R^2 de 89%, 83.40%, 0.80% y 80.44% respectivamente como se muestra en la figura 9, en el cual se muestran el coeficiente de determinación de cada índice de vegetación.

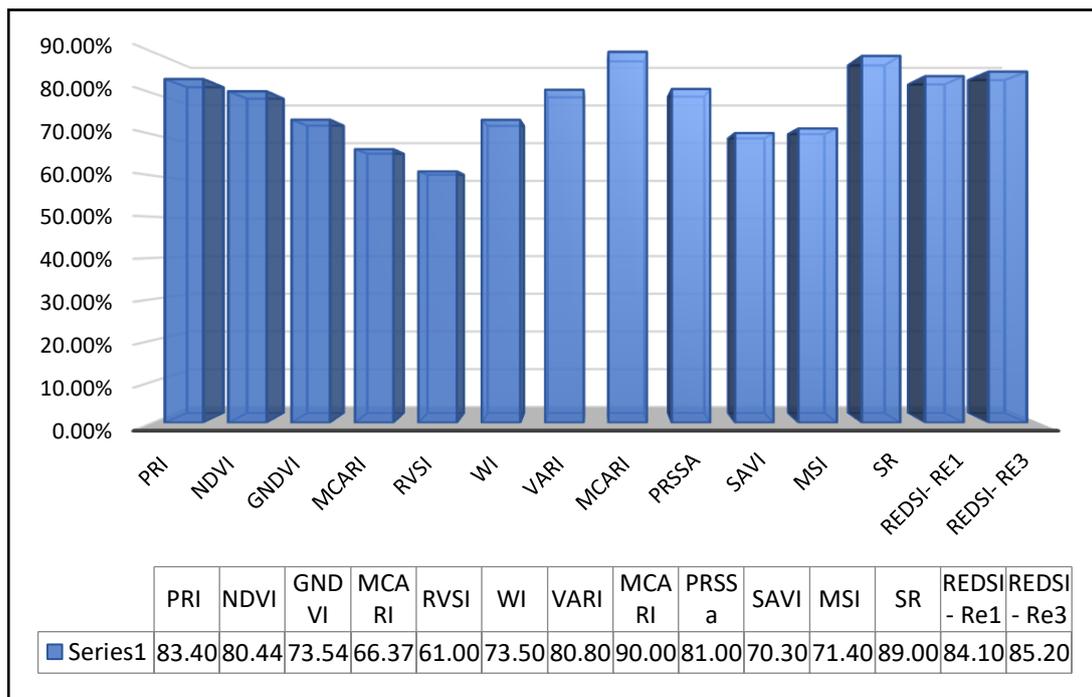


Figura 9. Gráfico de barras de los índices de vegetación relacionado con el coeficiente de determinación R^2 .

La figura 9, muestra los resultados de investigaciones del análisis de correlación entre cada índice de vegetación (13 IV). El coeficiente de determinación R^2 , muestra que el Índice de Relación Simple (SR) y el Índice de Reflectancia Fotosintética (PRI) con R^2 de 89.00% y 83.40% tienen una mayor relación con la gravedad de la enfermedad. Asimismo, el Índices de Reflectancia Fotosintética (PRI), el Índice de Vegetación de diferencia Normalizada (NDVI) y el Índice de Vegetación Normalizada Verde (GNDVI) son los índices más utilizados en las investigaciones para la detección de plagas y enfermedades con un 70%, 50%, 50% respectivamente.

Como se mostró en la teoría los algoritmos de clasificación son: Red Neural Artificial (ANN), Soporte de Maquina Vectorial (SVM), Analisis discriminante lineal y cuadrático (LDA), Análisis discriminante cuadrático (QDA), Red Neural convencional (CNN), Vecino k-más cercano (KNN) y Red Neural de Propagación hacia atrás (BPNN) el cual en la tabla 9 plasmamos los dos algoritmos más

utilizados para la clasificación de imagen y estos son: Algoritmos de clasificación Red Neural Artificial (ANN) y Soporte de Maquina Vectorial (SVM)

Tabla 09. Algoritmos de clasificación Red Neural Artificial (ANN), Soporte de Maquina Vectorial (SVM) y su coeficiente de determinación (R^2).

Referencias	Planta	Plagas y/o enfermedades	Algoritmos de clasificación	Precisión R^2
Rumpf, et al. ,2010, pp .91-99	Remolacha	Cercospora Beticola	SVM	97.00%
Wang, et al., 2012.p.38-48	Cebolla	Piel agria	SVM	87.14%
Kulkarni et al. ,2012, pp 3661-3664	Granada	Tizón Bacteriano	ANN	91.00%
García et al., 2013, pp. 106-115	Cítricos	Huanglongbing	SVM	92.00%
Cáceres, Amaya y Ramos ,2015, pp 274 -276	Flor de azúcar	Babosas, Caracoles, Arañas Rojas Y Minadoras De Hojas	SVM	97.00%
			ANN	98.50%
Bhange y Hingolowala, 2015, pp 280-288	Granada	Tizón Bacteriano	ANN	82.00%
Pujari, et al., 2015, p. 1806	Hortalizas	antracnosis, en polvo moho, óxido, downey moho, tizón temprano, tizón tardío	ANN	90.72%
			SVM	87.25%
Singh y Misra, 2017	Pinos	enfermedad de la pequeña hoja	ANN	91.00%
			SVM	95.71%
Zhang, et al.,2019, p. 9, Kuricheti y Supriya, 2019, p.548	Trigo	Roya de la hoja de trigo	SVM	93.00%

Fuente: Elaboración Propia.

Entre los algoritmos de clasificación, vale la pena señalar que los Soportes de Maquina Vectorial (SVM) se han aplicado ampliamente en el monitoreo y

detección de una variedad de plagas y enfermedades de plantas. El SVM ha logrado el reconocimiento temprano de la roya de la hoja de trigo con una precisión del 93.00% (Zhang, et al. 2019, p. 9). En la tabla 9, se observa que el algoritmo SVM es el más utilizado para el monitoreo y detección de plagas y enfermedades. En algunos escenarios complicados, las Redes Neurales Artificiales (ANN) exhiben una fuerte capacidad en monitoreo de plagas y enfermedades de plantas. En la figura 10, se observa los algoritmos más utilizados en diferentes investigaciones como: ANN y SVM, el cual visualizamos que el algoritmo SVM tiene un mayor coeficiente de determinación R^2 de 92, 73% y el ANN con un 90.64%.

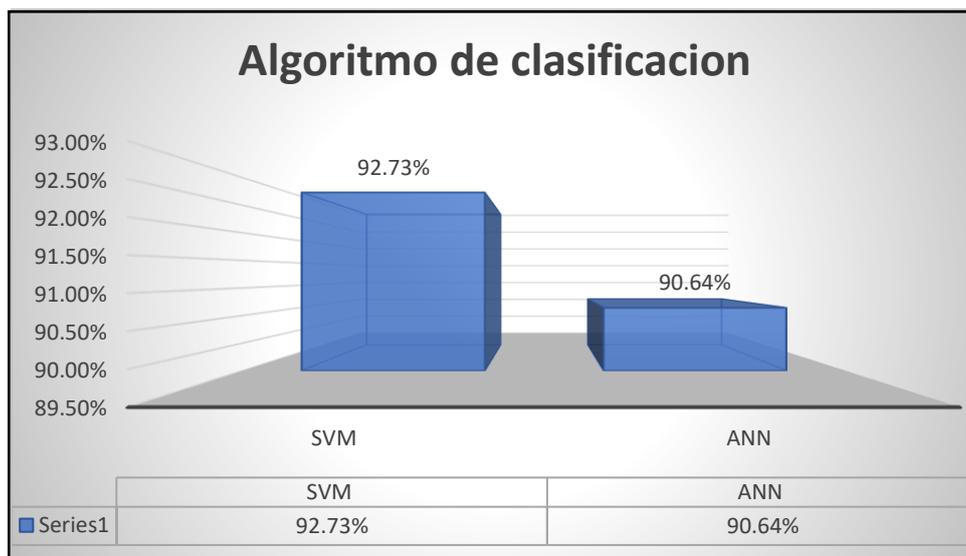


Figura 10. Gráfico de barra de los Algoritmos de clasificación ANN y SVM.

La figura 10, presenta un gráfico de barras de los dos algoritmos más utilizados en los estudios de clasificación de imagen para la detección de plagas y enfermedades, el cual estos algoritmos son utilizados para clasificar las partes de la planta sana de la enferma mediante una imagen a escala de grises. Según los estudios revisados el algoritmo más utilizado es SVM (Soporte de maquina vectorial) con un 70%.

La tabla 10, mostrada a continuación contiene el coeficiente de determinación R^2 de los algoritmos de segmentación los cuales son: Intensidad de saturación de color (HSI), Algoritmo K-means clustering y Algoritmo Umbral de Otsu y su porcentaje de aceptación.

Tabla 10. Algoritmos de segmentación de Intensidad de saturación de color (HSI), Algoritmo K-means clustering y Algoritmo Umbral de Otsu y su porcentaje de aceptación.

Referencias	Planta	Plagas y/o enfermedades	Algoritmos de segmentación	Precisión R ²
Pydipati, Burks y Lee, 2005, p. 2013; Kuricheti y Supriya, 2019 p. 546	Cítricos	Manchas grasas	HSI	95.00%
Gwan, et al. 2009, p. 8	Cítricos	Melanosa	HSI	96.70%
Wang, Jia Y Zhou, 2019, parr. 1; Phadikar Y Sil, 2008, p. 420; Singh, 2018, p. 341	Arroz	Rodillo de hoja de arroz	HSI	94.00%
Pawan, Warne Y Ganorkar, 2015, P. 429	Algodón	Alternaria, Cercospora y Mancha de hoja	K-means Clustering	80.56%
Singh y Misra, 2017	Pinos	enfermedad de la pequeña hoja	K- means clustering	86.54%
Castrillon, et al. 2017, pp 7-19	café	broca	umbral de otsu	92.00%
Caballero, et al.2015, pp 217-222	maíz y girasol	mala hierbas	umbral de otsu	94.89%
Marcial, M.2017, pp 1-101	maíz	varios	umbral de otsu	94.40%
Moacir, et al. 2016, pp 217-222	caña de azúcar, eucalipto	Mancha de anillo, pulgón del maíz	umbral de otsu	93.01%
				71.20%

Fuente: Elaboración propia

Entre los algoritmos de segmentación, cabe señalar que el algoritmo de Intensidad de saturación de color (HSI), tiene un mayor coeficiente de determinación R² de 96.70%, ya que el HSI desacopla el brillo de la imagen a partir de sus componentes de color HSI (Color, Saturación e Intensidad). En la tabla 11 se observa que el algoritmo de K-means clustering presento un R² de 86.54%, el cual indica que es el algoritmo más sensible para segmentar una

imagen, en cambio el algoritmo de Umbral de Otsu obtuvo un R^2 de 89.10%, siendo también el algoritmo más utilizado.

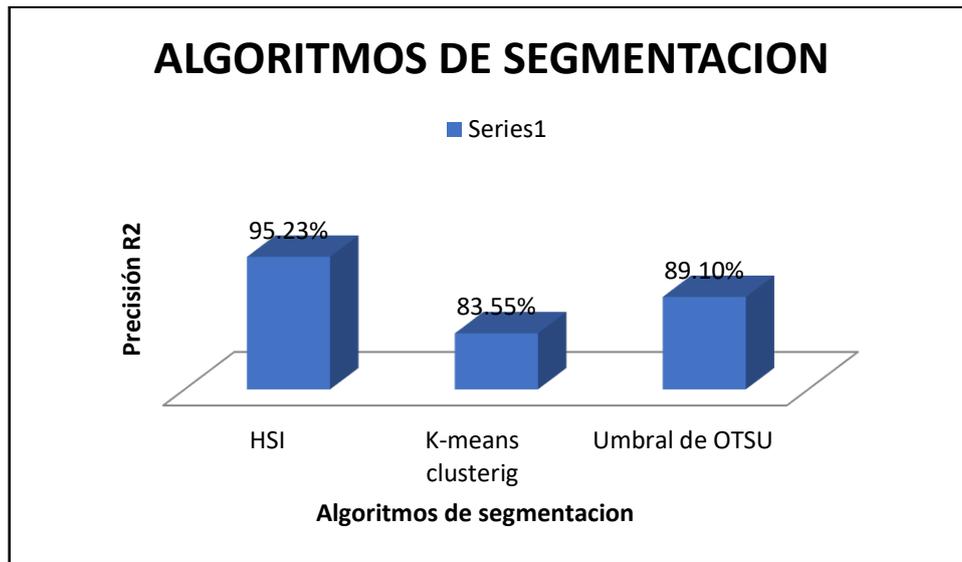


Figura 11. Gráfico de los algoritmos de segmentación relacionado con el coeficiente de determinación R^2 .

La figura 11, presenta un gráfico de barras donde representa los resultados del coeficiente de determinación R^2 , el cual muestra el nivel de precisión de cada algoritmos en diferentes investigaciones para la segmentación de imagen para la detección de plagas y enfermedades en las plantas, siendo así que se observa que el algoritmos que contiene mayor grado de precisión es el Algoritmo de Intensidad de Saturación de Color (HSI) con un R^2 de 95.23% debido a que este describe color, pureza de color y brillo de la imagen, mientras que el Umbral de Otsu obtuvo una nivel de precisión del 89.10%, ya que este algoritmo se utiliza cuando existe una clara diferencia entre los objetos extraídos del fondo de la escena. Por último, el algoritmo K-means clustering obtuvo un nivel de precisión de 83.55% debido a que es el principal clasificador de componentes para segmentar plantas enfermas (Singh, 2016, p. 9).

V. CONCLUSIONES

Las conclusiones de la investigación fueron las siguientes:

- Los índices de vegetación recopilados en la tabla 08, muestran el coeficiente de determinación R^2 de cada IV para la detección de plagas y enfermedades. Los resultados de los estudios indican que los índices de vegetación podrían ser utilizados para la clasificación de plagas y enfermedades. El análisis de regresión recopilada de cada índice de vegetación sirve para evaluar la capacidad de los IV en la estimación de la gravedad de la enfermedad. Se determinó que SR, REDSI, PRI, PRSSa, VARI y NDVI, tienen un mayor coeficiente de determinación (R^2) indicando una fuerte relación con la gravedad de las enfermedades. Los resultados de la clasificación mostraron que PRI, NDVI Y GNDVI son los IV más utilizados. Cabe resaltar que todos los índices indicados en la tabla 08 contribuyen para ver el estado del cultivo y detección de plagas y enfermedades.
- Este trabajo de investigación discutió diversas técnicas de segmentación de enfermedad y plagas de la planta, también algunas características de extracción y técnicas de clasificación de enfermedad de cultivos. El uso de ANN es uno de los algoritmos de clasificación más usados por los autores en sus investigaciones teniendo un grado de precisión de 90.64%, asimismo el algoritmo de Soporte de maquina vectorial (SVM) según Behmam et al. (2014) indican que SVR es potencialmente una alternativa prometedora a los modelos de predicción existentes (p. 15) teniendo un grado de precisión de 92.73%. De estos dos métodos, podemos identificar y clasificar que los dos son buenos para la clasificación de plagas y enfermedades. El algoritmo de segmentación que logro la mayor precisión de segmentación es el Algoritmo Intensidad de saturación de color (HSI) con un coeficiente de determinación R^2 de 95.23%, por lo que se sugiere que sería mejor utilizar un conjunto de características de textura de matiz, saturación e intensidad de color reducidas para diferenciar las enfermedades y plagas de las plantas.
- La detección y clasificación precisa de plagas y enfermedades de las plantas es muy importante para un cultivo exitoso y esto se puede lograr

hacer mediante el procesamiento de imágenes, el cual en esta revisión bibliográfica se describió los procesos metodológicos a seguir para la detección de plagas y enfermedades. Esta investigación describió las técnicas para clasificar, segmentar y extraer características de las plantas infectadas por plagas y enfermedades

VI. RECOMENDACIONES

Basado en nuestros resultados obtenidos, en este trabajo de investigación se ha podido conocer los diferentes procesos metodológicos de procesamiento de imágenes satelitales para poder detectar las plagas y enfermedades en los cultivos agrícolas. Lo cual con esta investigación permitirá poder aplicar las teorías y metodologías a estudios futuros y que permitirá realizar en campo.

- ✓ Se recomienda realizar más trabajos de investigación utilizando las diferentes técnicas como implementación de índices de vegetación o algoritmo para la para detección de plagas y enfermedades, ya que estas son un problema que sufren todos los agricultores en diversos cultivos.
- ✓ Asimismo, realizar la combinación de los modelos de simulación de cultivos existentes mejorar la confiabilidad de los sistemas de soporte de decisiones y contribuirá a una mejor gestión en la agricultura.
- ✓ Realizar una actualización constantemente de los procesos metodológicos de procesamiento de imágenes satelitales, con el propósito de verificar la evaluación de los cambios de las diferentes técnicas que se pueden implementar como los índices de vegetación o algoritmo.
- ✓ Para futuras investigaciones se debe realizar estudios y generar una base de datos de todos índices de vegetación relacionado para la detección de las plagas y enfermedades.

REFERENCIAS BIBLIOGRAFICAS

1. ABDUL, Hazli, BIN, Muhammad, WADI, Sulaiman, LOUIS, Gabor, STERCKX, Karel, SOLIMAN, Waleed y DUTTA, Joydeep. Applied light-side coupling with optimized spiral-patterned zinc oxide nanorod coatings for multiple optical channel alcohol vapor sensing. *Journal of Nanophotonics* [en línea]. julio – setiembre 2016, vol. 10, N° 3. [Fecha de consulta :15 de abril del 2020]. Disponible <https://doi.org/10.1117/1.JNP.10.036009> ISSN: 1988-8740
2. ABDULRIDHA, J., AMPATZIDIS, Y., EHSANI, R., y DE CASTRO, A. I. Evaluating the performance of spectral features and multivariate analysis tools to detect laurel wilt disease and nutritional deficiency in avocado. *Computers and Electronics in Agriculture* [en línea]. 2018. vol. 155, págs. 203–211,[Fecha de consulta : 24 de junio] . Disponible en : doi: 10.1016/j.compag.2018.10.016.
3. AGUILAR, Heileen , MORA, Rodolfo y VARGAS, Christian. Metodología para la corrección atmosférica de imágenes aéreas, rápidas y spot landsat 8 con el módulo de flash del software envi : *Revista Geográfica de América Central* [en línea]. julio-diciembre 2014, vol 2. n.º53. págs. 39-59,[Fecha de consulta : 30 de abril] . Disponible en : <https://www.revistas.una.ac.cr/index.php/geografica/article/view/6609> ISSN 1011-48X
4. Sentinel: Una Nueva Puerta Para La Agricultura De Precisión. [Mensaje en un blog] 11-07-2017. Recuperado de <https://www.agroptima.com/es/blog/sentinel-agricultura-precision/>
5. ANAND, R., VENI, S., y ARAVINTH, J. An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method. 2016 International Conference on Recent Trends in Information Technology (ICRTIT).2016. [Fecha de consulta : 26 de junio del 2020] . Disponible en : [doi:10.1109/icrtit.2016.7569531](https://doi.org/10.1109/icrtit.2016.7569531).
6. ANGDER- EGG, Esequiel, Técnicas de investigación social, 1995, Editorial LUMEN, 24ª edición. [Fecha de consulta : 01 de junio] . Disponible en :

https://d1wqtxts1xzle7.cloudfront.net/36539653/IT_Ander-Egg_1.pdf?1423229204=&response-content-disposition=inline%3B+filename%3DTECNICAS_DE_INVESTIGACION_SOCIAL.pdf&Expires=1591201776&Signature=Ob6Y4MrOKnsAOUF323GXXC3FIFsYEKh7OaSk~UnPmERAx42-uineToeM4FAB5ATan03FtZsmuaiu8I4xkcqdfllNjPSK-QoEh2xzoseci2tPH9YK1PY~C164-Ve9FPCUpGaXaYqDVsGFepzZyuJcknACUXuoEfK8EpBgNOakZYZ35IPn7K5vV9YUTz8irlf2VF0Ky94TvIIPgEgqZzBdMFVJOURx9jBQnTSLpncFnruBxTzTyP6xAusrVG3B11A5MtkokbCg1gGq6dzo5MP-yNPmirtZyqlz3~jDD5UNoQqR7q7h1NwKyn5qiG-L0TU9G69OhrJIDV1FuaEGcTuP1g_&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA

7. BABANKUMAR, B., RANGOLI, S., RITULA, T. Y GAURAV S., A comparison between satellite based and drone based remote sensing technology to achieve sustainable development: a review, *Journal of Agriculture and Environment for International Development* [en línea]. 2017.vol. 111. N° 2.págs. 383 – 407, [Fecha de consulta : 10 de junio] . Disponible en: DOI: [10.12895/jaeid.20172.690](https://doi.org/10.12895/jaeid.20172.690)
8. BAURIEGEL, E., GIEBEL, A., GEYER, M., SCHMIDT, U. y HERPPICH, W.B. Early detection of Fusarium infection in wheat using hyper-spectral imaging, *Computers and Electronics in Agriculture* [en línea]. Febrero del 2011, vol. 75, págs. 304-312, [Fecha de consulta : 20 de abril] . Disponible en <https://www.sciencedirect.com/science/article/pii/S0168169910002565>
9. BALBONTÍN, Claudio, ODI , Magali ,POBLETE , Rodolfo, GARRILLO , Jesus , CAMPOS Isidro y CALERA, Alfonso . Uso de herramienta de teledetección y SIG para el manejo del riego en los cultivos .La SERENE : Instituto de Investigaciones Agropecuarias [en línea]. 2016. pág. 50 , [fecha de consulta :13 de mayo del 2020]. Disponible en: <http://biblioteca.inia.cl/medios/biblioteca/boletines/NR40534.pdf>.ISSN 0717 – 4829, ISSN 0717 – 4829

10. BEBBER, Daniel, FIELD, Elsa, HENG, Gui, PETER, Mortimer, TIMOTHY Sarah J. Gurr. Many unreported crop pests and pathogens are probably already present. *Glob change* [en línea]. 9 de mayo del 2019, vol. 25, n.º 8, págs. 2703-2713,[Fecha de consulta : 20 de abril] . Disponible en :
<https://doi.org/10.1111/gcb.14698>

11. BERRA, E., PEREZ, M., y CUAUTLE, J. Redes neurales artificiales para la detección de plagas en cultivos de jitomate bajo invernadero [en línea], 04 de noviembre de 2019. Disponible en:
https://www.researchgate.net/publication/337012289_Neural_networks_for_the_detection_of_plagues_in_cultivation_of_tomato_under_greenhouse

12. BHANGE, Manisha y HINGOLIWALA, H.A. Smart Farming: Pomegranate Disease Detection Using Image Processing. *Procedia Computer Science* [en línea]. 2015, vol. 58, págs. 280 – 288,[Fecha de consulta : 09 de junio del 2020]. Disponible en: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

13. BLANCO, E., BONET, J. A. y EIZAGUIRRE, M. Uso de imágenes satélite Landsat para la detección de rodales de Pinus nigra Arn. y Pinus sylvestris L. afectados por escolítidos, *Investigación Agraria: Sistemas y Recursos Forestales* [en línea]. 2009, Vol. 18, N.º.3, págs. 264-275, Fecha de consulta : [20 marzo 2010]. Disponible <https://repositori.udl.cat/handle/10459.1/44652> . ISSN: 1131-7965

14. BLACKBURN, G. A. Spectral índice for estimating photosynthetic pigment concentrations: A test using senescent tree leaves. *International Journal of Remote Sensing* [en línea]. 24 September 2013, vol. 19, no. 4, 657-675,[Fecha de consulta : 25 mayo 2010].Disponible en:
<https://www.tandfonline.com/doi/abs/10.1080/014311698215919>

15. BRECHELT, Andrea. Manejo Ecológico de Plagas y enfermedades. *Red de Acción en Plaguicidas y sus Alternativas para América Latina* [en línea]. Abril de 2004. Disponible en:
http://www.academia.edu/download/60043730/Manejo_Ecologico_de_Plagas_A.Bretchel20190717-63327-k5j6x9.pdf

16. CABALLERO, Daniel, CALVINI, Rosalba, y AMIGO, José. Hyperspectral imaging in crop fields: precision agriculture, *Data management in science and technology* [en línea]. vol. 32, págs. 453-473, [Fecha de consulta :22 de abril del 2020]. Disponible en: <https://doi.org/10.1016/B978-0-444-63977-6.00018-3>
17. CASERES, C.A., AMAYA, D. y RAMOS, O.L. Methodology for pest damage recognition in Begonia semperflorens link & Otto (sugar flower) crop through image Processing, *Plant and Crop Protection*. [en línea], 2015, vol. 64, N° 3, págs. 273 - 279, [Fecha de consulta :22 de junio del 2020]. Disponible en: [doi: http:// dx.doi.org/10.15446/acag.v64n3.42657](http://dx.doi.org/10.15446/acag.v64n3.42657) - ISSN 2323-0118
18. CABALLERO, J., PEÑA J., TORRES J., LÓPEZ F. Optimización de algoritmos para segmentación por valor umbral aplicado a detección de malas hierbas en imágenes procedentes de vehículos aéreos no tripulados. *Instituto de Agricultura Sostenible, IAS-CSIC* [en línea] .2015, XV Congreso de la Sociedad Española de Malherbología . [Fecha de consulta : 21 de junio del 2020]. Disponible en: <https://www.researchgate.net/publication/283084895> Optimizacion de algoritmos de segmentacion por valor umbral aplicado a deteccion de malas hierbas en imagenes procedentes de vehiculos aereos no tripulados
19. CACERES, Camilo, ARMAYA, Darío y RAMOS, Olga. Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia semperflorens (flor de azúcar). *Sanidad Vegetal y Protección de Cultivos* [en línea]. 06 de junio del 2014, vol. 64, n°. 3, Pag 273-279, [7 de mayo del 2020]. Disponible en: doi: <http://dx.doi.org/10.15446/acag.v64n3.42657> ISSN 0120-2812 | e-ISSN 2323-0118
20. CAMARGO, A., y Smith, J. S. An image-processing based algoritmo to automatically identify plant disease visual symptoms. *Biosystems Engineering* [en línea]. 2009, vol. 102, n.º 1, págs. 9-21, [Fecha de consulta :26 de abril del 2020] . Disponible en:

- <https://www.tib.eu/en/search/id/BLSE%3ARN242256486/An-image-processing-based-algorithm-to-automatically/>
21. CAMARA DE COMERCIO. En el foro “Perú, camino hacia una agricultura sustentable” de la CCL [en línea]. 28 de noviembre del 2019 .[Fecha de consulta :30 de mayo del 2020] .Disponible en: <https://www.lampadia.com/opiniones/cmara-de-comercio-de-lima/sector-agrario-aporta-54-del-pbi-y-emplea-a-mas-de-4-millones-de-peruanos/>
 22. CANDIAGO, Sebastián, REMONDINO, Fabio, DE GIGLIO, Michaela, DEBBINI, Marco y GATTELLI, Mario. Evaluating Multispectral Imagen and Vegetation Indices for Precision Farming Applications from UAV Images [en línea]. 2 de abril del 2015, vol. 7, nº .4, [Fecha de consulta :15 de mayo del 2020]. Disponible en: <https://www.mdpi.com/2072-4292/7/4/4026> ISSN 2072-4292
 23. CASTILLO, Edelmira y VASQUEZ, Marta. El rigor metodológico en la investigación cualitativa. Colombia medica [en línea]. 2003, vol.34, nº.3,164-167,[Fecha de consulta 12 de junio de 2020]. ISSN:0120-8322. Disponible en: <https://www.redalyc.org/pdf/283/28334309.pdf>
 24. CASTRILLON, Juan, SANZ, Juan, JIMENA, Paula. Algoritmo para la identificación de café lavado afectado por la broca del café. *Cenicafé* [en línea], 2017. vol.68, nº.2, págs. 7-19, [Fecha de consulta : 20 de junio del 2020]. Disponible en: <https://www.researchgate.net/publication/330524704> Algoritmo Para la identificación de Cafe Lavado Afectado por la Broca del Cafe
 25. CEJA, Ramon, GONZALES, Diego, RUIZ, José, RENDON, Luis y FLORES José. Detection de restricciones en la producción de agave azul Agave tequilana Weber var. azul) mediante percepción remota. *Terra Latinoamericana* [en línea]. Febrero – junio 2017, vol. 35,págs. 259-268, [Fecha de consulta :2 de abril del 2020] , págs. pag 7063-7081. Disponible en: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0187-57792017000300259
 26. CORBETTA, P. Metodología y técnica de investigación Social. España [en línea]. 2007, pp. 422. Disponible en : <https://www.librosuned.com/LU5036/Metodolog%C3%ADa-y->

<t%C3%A9cnicas-de-investigaci%C3%B3n-social--.aspx> ISBN:

9788448156107

27. DÍAZ García -Cervigon , Juan José. Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión. Tesis (Master) Madrid : Facultad de geografía e historia, 2015. Disponible en : https://eprints.ucm.es/31423/1/TFM_Juan_Diaz_Cervignon.pdf
28. DELEGIDO, Jesús, VERRELST, Jochem, Alonso, Luis, y MORENO, José. Evaluation of sentinel-2 red-edge bands for empirical estimation of Green LAI and chlorophyll content. *Sensors* [en línea] .8 de julio de 2011, vol. 11, n.º 7, [Fecha de consulta :2 de abril del 2020] , págs. pag 7063-7081. Disponible en: <https://doi.org/10.3390/s110707063>.
29. DOUGLAS, Angela. Strategies for enhanced crop resistance to insect pests. *Review of plant biology* [en línea]. noviembre del 2017, vol. 69 .[Fecha de consulta :23 de abril del 2020] , págs. 637 660. Disponible en : <https://doi.org/10.1146/annurev-arplant-042817040248>
30. ELIZALDE, Oscar. El rigor en la investigación cualitativa. 3 de noviembre 2017. <https://www.lamalditatis.org/post/rigor-en-la-investigacion-cualitativa-dependencia>
31. FAO. Agencia Agraria de Noticias. 16 de Julio de 2015. Disponible en: <https://agraria.pe/noticias/40-de-la-produccion-de-alimento-se-pierde-8729>
32. FAO. Organización de la Naciones Unidas para la Alimentación y la Agricultura. 15 de marzo de 2018. Disponible en: <http://www.fao.org/emergencias/la-fao-en-accion/historias/historia-detalle/es/c/1107399/>.
33. FAO. Plagas y enfermedades de las plantas (2020). Disponible en : <http://www.fao.org/emergencias/tipos-de-peligros-y-de-emergencias/plagas-y-enfermedades-de-las-plantas/es/>
34. FAJARDO, Luis. Firmas espectrales: componentes y necesidades de metadatos. Centro de Investigación y Desarrollo en Información Geográfica [en línea]. Diciembre del 2018. [fecha de consulta: 08 de mayo del 2020]. Disponible en:

https://www.researchgate.net/publication/334545971_Firmas_Espectrales

S

35. FENG, W., QI, S., HENG, Y., ZHOU, Y., WU, Y., LIU, W., LI, X. Canopy Vegetation Indices from In situ Hyperspectral Data to Assess Plant Water Status of Winter Wheat under Powdery Mildew Stress. *Frontiers in Plant Science*, 8 [en línea]. 2017. [fecha de consulta: 20 de julio de 2020]. Disponible en: doi:10.3389/fpls.2017.01219
36. FERREYRA, Adriana. La Observación de la tierra desde el espacio. Imágenes satelitales Un recurso disponible. *Instituto Nacional de Tecnología Agropecuaria* [en línea]. Abril 2016. [fecha de consulta: 10 de abril del 2020] Disponible en: https://inta.gob.ar/sites/default/files/pag_57_ferreyra.jpg
37. FANG, Yi y RAMARAJA, RAMASAMY. Current and Prospective Methods for plant disease detection. *Biosensors* [en línea]. julio-agosto 2015, n.º3, págs. pag 537-561. [fecha de consulta: 16 de marzo de 2020] Disponible en: <https://doi.org/10.3390/bios5030537> .ISSN 2079-6374
38. FRANKE, J., y MENZ, G. Multi-temporal wheat disease detection by multi-spectral remote sensing. *Precision Agriculture* [en línea] 24 de junio 2007. vol. 8, n.º3, págs, 161-172. [fecha de consulta: 21 de marzo de 2020] Disponible en: <https://link.springer.com/article/10.1007/s11119-007-9036-y> Doi:10.1007/s11119-007-9036-y
39. GALINDO, Gustavo , ESPEJO , Oscar , VERGARA, Katherine y, CABRERA, Edersson . Protocolo de procesamiento digital de imagen para la cuantificación de la deforestación en Colombia V.2. BOGOTÁ D.V. : *Editorial Scripto Gómez y Rosales Asociados Cia. Ltda*, 2014, págs. 63 ISBN :978 958 8067.
40. GARCÍA, Cipriano y RODRÍGUEZ, Guadalupe. Problemática y riesgo ambiental uso de plaguicidas en Sinaloa. *Ra Ximbi* [en línea]. setiembre-diciembre 2012, vol. 8, n.º.3 págs. 1-10, [fecha de consulta :17 de abril del 2020] Disponible en: <http://www.revistas.unam.mx/index.php/rxm/article/view/53787> ISSN: 1665-0441

41. GARCIA, Ruiz, F., SANKARAN, S., Maja, J. M., LEE, W. S., RASMUSSEN, J., & EHSANI, R. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture* [en línea]. 2013, vol. 91, págs. 106–115. [Fecha de consulta : 12 de junio del 2020]. Disponible en: <https://doi.org/10.1016/j.compag.2012.12.002>
42. GEOSPACIAL. Arcata Harpts. 2014. Disponible en: http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson3-1/bands.html
43. GONZALES Huisa, Anthony Ricardo. Diseño de una cámara multiespectral de 4 bandas para agricultura de precisión. Tesis (Ingeniero electrónico). Lima. Pontifica universidad católica del Perú ,2015. Disponible en : <http://hdl.handle.net/20.500.12404/5964>
44. GUNES, Ali., KALKAN, Habil., y DURMUS, Efkán. Optimizing the color-to-grayscale conversion for image classification. *Department of Computer Engineering* [en línea]. Febrero -octubre 2015, vol. 10, N°.5, págs. 853-860. [Fecha de consulta : 05 de mayo del 2020]. Disponible en: Doi: 10.1007/s11760-015-0828-7. <https://link.springer.com/article/10.1007/s11760-015-0828-7>
45. HIARY, H. AL, S. BANI, AHMAD, M. REYALAT, M. BRAIK AND Z. ALRAHAMNEH. *Fast and Accurate Detection and Classification of Plant Diseases*. International Journal of Computer Applications [en línea]. marzo de 2011, vol.17, n.º 1. págs. 0975-8887. [Fecha de consulta :17 de abril del 2020]. Disponible en: https://s3.amazonaws.com/academia.edu.documents/61141010/Detection_and_Classification_of_Plant_Diseases20191105-2852
46. HALLIK, L., KAZANTSEV, T., KUUSK, A., GALMES, J., TOMAS, M., NIINEMETS, U. Generality of relationships between leaf pigment contents and spectral vegetation indices in Mallorca (Spain). *Reg. Environ. Change*. 2017, vol. 17. págs. 2097–2109.
47. HANTSON, S.; CHUVIECO, E.; PONS, X.; DOMINGO, C.; CEA, C.; MORÉ, G. Cadena de pre-procesamiento estándar para las imágenes Landsat del plan nacional de teledetección. *Revista de Teledetección* [en

- línea], junio-octubre 2011, Vol. 36, págs. 51-61. [Fecha de consulta :15 de abril del 2020]. Disponible en: http://www.geogra.uah.es/images/Documentos/emilio/PDF/hantson2011_b.pdf . ISSN: 1988-8740
48. HOYOS, Jhon, POSADA, William y CERON, María. Fotografía multiespectral para el diagnóstico fitosanitario de pasto kikuyo (*Cenchrus clandestinus* (Hochst ex Chiov) Morrone). *Acta agron* [en línea]. Febrero de 2019, vol. 68, N°.1, págs. 61-67 [Fecha de consulta :08 de mayo del 2020]. Disponible en: doi: <https://doi.org/10.15446/acag.v68n1.75662> . ISSN 0120-2812 | e-ISSN 2323-0118
49. HUANG, W., LAMB, D., 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* [en línea].2007, vol.8,nº4, págs. 187-197 Disponible en: <https://link.springer.com/article/10.1007/s11119-007-9038-9>
50. HUDDAR, Sushma, GOWRI, Swarna, KEERTHANA, K., VASANTHI, S., y RUPANAGUDI, Rao. Novel algorithm for segmentation and automatic identification of pests on plants using image processing. *Third International Conference on Computing, Communication and Networking Technologies (ICCCNT'12)* [en línea]. Julio 2012. [Fecha de consulta :15 de abril del 2020]. Disponible [doi:10.1109/iccant.2012.6396012](https://doi.org/10.1109/iccant.2012.6396012)
51. ISIP, M., ALBERTO, R., y BIAGTAN, A. Biagtan. Exploring vegetation indices adequate in detecting twister disease of onion using Sentinel-2 imagery. *Escupio .inf.Res* [en línea].22 octubre 2019. [Fecha de consulta : 12 de mayo del 2020]. Disponible en: <https://doi.org/10.1007/s41324-019-00297-7> .
52. JHURIA, M., KUMAR, A., y BORSE, R. Image processing for smart farming: Detection of disease and fruitgrading. *IEEE Second Internacional Conference on Image Informacion Proceseing (ICIIP-2013)* [en línea]. 2013. [Fecha de consulta :18 de abril del 2020] Disponible: Doi:10.1109/iciip.2013.6707647.

53. JIMENEZ, Edgardo. Metodos de control de plagas. Tesis (doctor Entomología) Nicaragua: Universidad Nacional de Agraria, 2009. Disponible <https://cenida.una.edu.ni/relectronicos/RENH10J61me.pdf>
54. KANAN, Christopher y COTRELL, Garrison Color-to-Grayscale: Does the Method Matter in Image Recognition? *Department of Computer Science and Engineering* [en línea]. febrero 2012. [Fecha de consulta :3 de junio del 2020] Disponible: <https://www.researchgate.net/publication/221755665>
55. K. Thenmozhi y US Reddy. Técnicas de procesamiento de imágenes para la detección de formas de insectos en cultivos de campo. *Conferencia Internacional de Informática Inventiva e Informática de 2017 (ICICI)*, Coimbatore [en línea]. 28 de mayo del 2018, págs. 699-704. [Fecha de consulta :23 de abril del 2020] Disponible: <https://ieeexplore.ieee.org/abstract/document/8365226>
56. KHIRADE, SD y PATIL, AB. Plant Disease Detection Using Image Processing. *International Conference on Computing communication Control and Automation* [en línea]. 2015. [Fecha de consulta :15 de abril del 2020] Disponible en: doi: 10.1109 / iccubea.2015.153., <http://hub.tw/https://ieeexplore.ieee.org/abstract/document/7155951>,
57. KIRAN R. Gavhale y UJWALLA Gawande. An Overview of the Research on Plant Leaves Disease Detection Using Image Processing Techniques. *Journal of Computer Engineering* [en línea]. Febrero 2014, vol 16, n°. 1. págs. 10-16. [Fecha de consulta : 28 de abril del 2020]. Disponible en :e-ISSN: 2278-0661, p-ISSN: 2278-8727 <https://pdfs.semanticscholar.org/7792/ab664d5ab93c5e8c45b0c772627d40c962eb.pdf>
58. KORHONEN, Lauri., Hadi., PACKALEN, Petteri y RAUTIAINEN, Miina. Comparison of Sentinel-2 and Landsat 8 in the estimation of boreal forest canopy cover and leaf area index. *Remote Sensing of Environment. Agriculture* [en línea]. 15 de junio del 2017, vol. 195, págs. 259-274. [Fecha de consulta : 12 de mayo del 2020]. Disponible en Doi: <http://dx.doi.org/10.1016/j.rse.2017.03.021>.

59. KULKARNI, Anand y PATIL, Ashwin. Applying image processing technique o detection plant diseases. *International Journal of Modern Engineering Research (IJMER)* [en línea]. Septiembre- Octubre 2012, vol 2, n°. 5, págs. 3661-3664. Fecha de consulta :20 de abril del 2020]. Disponible:
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.416.9110&rep=rep1&type=pdf> ISSN: 2249-6645.
60. KUMBULA, S., MAFONGOYA, P., PEERBHAY, K., LOTTERING, R. y ISMAIL, R. Using Sentinel-2 multispectral images to map the occurrence of the cossid moth (*Coryphodema tritis*) in cucalyptus nitens plantations of mpmalanga, South Africa. *Remote Sensing* [en línea]. 31 de enero del 2019, vol. 11, n°.3. [Fecha de consulta :28 de abril del 2020]. Disponible en: <https://www.mdpi.com/2072-4292/11/3/278>.
61. KUMAR, Pradeep y RAY, Shibendu S. Detection of bacterial wilt disease (*Pseudomonas solancearum*) in Brinjal using hyperspectral remote sensing, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [en línea]. Febrero 2019, vol. 62, n°, 3 ,págs. 515-520. [Fecha de consulta : 02 de junio del 2020] Disponible en: <https://www.researchgate.net/publication/334741290>
62. KURICHETI, G., y SUPRIYA, P. Computer Vision Based Turmeric Leaf Disease Detection and Classification: A Step to Smart Agriculture. 2019 3rd *International Conference on Trends in Electronics and Informatics (ICOEI)*. 2019. [Fecha de consulta : 02 de junio del 2020] Disponible en: [doi:10.1109/icoei.2019.8862706](https://doi.org/10.1109/icoei.2019.8862706).
63. LABRADOR , Mauricio, ÉVORA, Juan y ARBELO, Manuel. Satelites de teledeccion para la gestion de territorio. [en linea] Consejería de Agricultura, Ganadería, Pesca y Aguas del Gobierno de Canarias. Gobierno de Canarias, Febrero 2012. [Fecha de consulta :02 mayo del 2020] .pág. 21. Disponible :
http://www.gmrcanarias.com/wpcontent/uploads/2016/01/20catalogo_satelites_es.pdf ISBN13:978-84-695-3276-8.
64. LI, Guanlin, MA, Zhanhong y WANG, Haiguang. Degvelopment of a single sheet automatic disease severity classification system based on image

- processing. Proceedings of the 2012 International Conference on Information Technology and Software Engineering [en línea].2012, págs. 665–675. [Fecha de consulta :10 de abril del 2020]. Disponible en: [Doi: 10.1007 / 978-3-642-34531-9_70](https://doi.org/10.1007/978-3-642-34531-9_70).
65. LUO, J., HUANG, W., ZHAO, J., ZHANG, J., ZHAO, C., y MA, R. Detecting Aphid Density of Winter Wheat Leaf Using Hyperspectral Measurements. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [en línea]. 11 de abril del 2013, vol. 6. n°.2, págs. 680–698. [Fecha de consulta :20 mayo del 2020]. Disponible en: [doi:10.1109/jstars.2013.2248345](https://doi.org/10.1109/jstars.2013.2248345)
<https://ieeexplore.ieee.org/abstract/document/6496156>
66. MARCIAL, M. Determinación de variables agronómicas del cultivo de maíz mediante imágenes obtenidas desde un vehículo aéreo no tripulado (vant), (maestro en ciencias y tecnología en agua). México. Instituto mexicano de tecnología en agua ,2017.
67. MIRIK, M., ANSLEY, R. J., MICHELS, G. J., & ELLIOTT, N. C. Spectral vegetation indices selected for quantifying Russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). *Precision Agriculture* [en línea]. 2012, Vol. 13, n°4, págs. 501–516. [Fecha de consulta :10 junio del 2020]. Disponible en: [doi:10.1007/s11119-012-9264-7](https://doi.org/10.1007/s11119-012-9264-7)
68. MIRANDA, Rosa. ¿Cuál es la importancia de la agricultura en el Perú de hoy?. Publicaciones económicas [en línea].05 de marzo del 2018. [Fecha de consulta :31 mayo del 2020]. Disponible en [:https://economica.pe/actualidad/1041-cual-es-la-verdadera-importancia-de-la-agricultura-en-el-peru-de-hoy](https://economica.pe/actualidad/1041-cual-es-la-verdadera-importancia-de-la-agricultura-en-el-peru-de-hoy)
69. MINAGRI, Plan estratégico sectorial multianual 2015-2021. [en línea] 2015. Disponible en: http://minagri.gob.pe/portal/download/pdf/pnapes/pesem_2015-2021.pdf
70. MINGHUA Zhang, ZHIHAO Qin, XUE Liu, SUSAN L. Ustin. Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation* [en línea] .2003, vol. 4 , pags. 295-310 pp [Fecha de consulta :20 setiembre del 2018] Disponible en :

<http://agis.ucdavis.edu/publications/2003/Detection%20of%20stress%20in%20tomatoes%20induced%20by%20late%20blight%20disease%20in.pdf>

71. MORENO Gázquez, Juan Daniel. Clasificación de imágenes multiespectrales e hiperespectrales de alta resolución para la obtención de cartografía temática en Maspalomas. Tesis (Master en ingeniería telecomunicaciones). Las Palmas de Gran Canaria : Universidad de Las Palmas de Gran Canaria, 2018.
72. MRUNALINI R., PRASHANT R. "infected leaf analysis and comparation by Otsu Threshold and K-Means Clustering. *International Journal of Advanced Research in Cumputer Science and Software Engiennering* [en línea], marzo 2012, vol 2, n° 3. [Fecha de consulta : 29 de mayo del 2020] .Disponible en: http://ijarcsse.com/Before_August_2017/docs/papers/March2012/volume_2_Issue_3/V2I300146.pdf
73. NA, S., XUMIN, L., y YONG, G. Research on k-means Clustering Algorithm: An improved k-means Clustering Algorithm. *Third International Symposium on Intelligent Information Tecnology and Security Informatics* [en línea]. 2010 [Fecha de consulta : 29 de mayo del 2020] .Disponible en: <https://ieeexplore.ieee.org/abstract/document/5453745>
74. NAIDU, R. A., PERRY, E. M., PIERCE, F. J., Y MEKURIA, T. The potential of spectral reflectance technique for the detection of Grapevine leafroll-associated virus-3 in two red-berried wine grape cultivars. *Computers and Electronics in Agriculture* [en línea]. abril del 2009, vol. 66 ,N°. 1, págs. 38–45. [Fecha de consulta : 20 de abril del 2020] . Disponible en : doi: 10.1016/j.compag.2008.11.007 <https://www.sciencedirect.com/science/article/pii/S0168169908002299>
75. NAZUL, I., KASHEM, M., AKTER, M y RAHMAN, J. An Approach Classifiers for Automatic Disease Detection and Classification of Plant Leaf. *Proceeding of the International Conference on Electrical, Computer and Telecommunication Engineering* [en línea] 2015. Disponible en: https://www.researchgate.net/profile/Md_Nazrul_Islam6/publication/275531091_An_Approach_to_Evaluate_Classifiers_for_Automatic_Disease_Detection_and_Classification_of_Plant_Leaf/links/553f3af10cf210c0bdaa

[cd83/An-Approach-to-Evaluate-Classifiers-for-Automatic-Disease-Detection-and-Classification-of-Plant-Leaf.pdf](#)

76. NOREÑA, Ana., ALCARAZ, Noemi., ROJAS, Juan y REBOLLEDO, Dinora. Aplicabilidad de los criterios de rigor y éticos en la investigación cualitativa. Colombia [en línea] 2012, n^o. 3, págs. 263-274. [11-de septiembre de 2012]. ISSN: 1657-5997. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=4322420>
77. OERKE, E.-C., y MAHLEIN, A.-K. Recent advances in sensing plant diseases for precision crop protection. *European journal of plant pathology* [en línea]. 27 de marzo del 2012, vol. 133, págs. 1997-209. [Fecha de consulta : 25 de abril del 2020] .Disponible en : doi: 10.1007 / s10658-011-9878-z. <https://link.springer.com/article/10.1007/s10658-011-9878-z>
78. OMRANI, Elham., KHOSHNEVISAN, Benyamin., SHAMSHIRBAND, Shahaboddin., SABOOHI, Hadi., BADRUL, Nor., NIZAM, Mohd. Potential of radial basis function-based support vector regression for apple disease detection. *Measurement* [en línea]. setiembre del 2014, vol. 55, págs. 512-519,[Fecha de consulta : 15 de abril del 2020].Disponible en : <http://dx.doi.org/10.1016/j.measurement.2014.05.033>
79. OÑA, Alberto, MORALES, María, TOLEDO, Lucia y TERNEUS, Carlos. Revisión sistemática del estado del arte de las Tecnologías de Información y Comunicación (TICS) y Seguridad Alimentaria. XVIII Congreso latino Iberoamérica de gestión tecnológica ALTEC 2019 Medellín.[en línea]. 2019, vol. 3 ,n^o.2. [Fecha de consulta : 26 de junio del 2020]. ISSN: 2594 -0937. Disponible en : https://www.researchgate.net/profile/Xavier_Ona2/publication/340363374_Revisión_sistemática_del_estado_del_arte_de_las_Tecnologías_de_Información_y_Comunicación_TICS_y_Seguridad_Alimentaria/links/5e8500f3a6fdcca789e8ce61/Revision-sistemática-del-estado-del-arte-de-las-Tecnologías-de-Información-y-Comunicación-TICS-y-Seguridad-Alimentaria.pdf
80. PHADIKAR, S., y SIL, J. Rice disease identification using pattern recognition techniques. 2008 11th *International Conference on Computer and Information Technology* [en línea]. 2018. [Fecha de consulta : 10 de abril del 2020]. Disponible en: doi:10.1109/iccitechn.2008.4803079. <https://ieeexplore.ieee.org/abstract/document/4803079>

81. PORCUNA, José. Manejo de plagas y enfermedades en producción agrícola. Sociedad Española de Agricultura Ecológica. 2015. [Fecha de consulta : 16 de abril del 2020] .Disponible en: https://www.alcoi.org/export/sites/default/es/areas/medi_ambient/cimal/d_escargas/MANEJO-PLAGAS-Y-ENFERMEDADES-EN-PRODUCCION-ECOLOGICA.pdf
82. PRABHAKAR, M., PRASAD, y. G., THIRUPATHI, M., SREEDEVI, G., DHARAJOTHI, B., y VENKATESWARLU, Use of ground based hyperspectral remote sensing for detection of stress in cotton caused by leafhopper (Hemiptera: Cicadellidae). *Computers and Electronics in Agriculture* [en línea]. Noviembre del 2011, vol. 79. n°. 2. págs. 189–198. [Fecha de consulta : 20 de abril del 2020] Disponible en: doi:10.1016/j.compag.2011.09.012
<https://www.sciencedirect.com/science/article/pii/S0168169911002274>
83. PUJARI. Jagadeesh , YAKKUNDIMATH, Rajesh y BYADGI , Abdulmunaf . Internacional Processing based Detection of fungal diseases in plants *Procedia Computer sciencia* [en línea]. 2015. vol. 46, pag 1802-1808, [Fecha de consulta :15 de abril del 2020] Disponible en: <https://doi.org/10.1016/j.procs.2015.02.137>
84. PYDIPATI, R., BURKS, T. Y LEE, W. S. Statistical and neural network classifiers for citrus disease detection using machine vision. *Transactions of the ASAE* [en línea]. 2005, vol.48, n°. 5, págs. 2007–2014. [Fecha de consulta :22 de junio del 2020]. Disponible en: doi:10.13031/2013.19994
<https://elibrary.asabe.org/abstract.asp?aid=19994>
85. REMBOLD, Felix, ATZBERGERM Clement, SAVIN, Igor y ROJAS, Oscar. Using Low Resolution Satellite Imagery for Yield Prediction and Yield Anomaly Detection. *Remote Sensing*. [en línea]. febrero – abril del 2013, vol. 5, pag 1704-1733. [Fecha de consulta : 07 de mayo del 2020] . Disponible en: www.mdpi.com/journal/remotesensing ISSN 2072-4292
86. RAMÍREZ, R., GONZÁLEZ, D., RUIZ, J., RENDÓN, L. Y FLORES, Detección de restricciones en la producción de agave azul (Agave tequilana Weber var. azul) mediante percepción remota. *Terra Latinoamericana* [en línea]. Febrero – junio del 2017, vol. 35, n°. 3, págs.

- 259-268. [Fecha de consulta : 06 de mayo del 2020]. Disponible en:
<http://www.scielo.org.mx/pdf/tl/v35n3/2395-8030-tl-35-03-00259.pdf>
87. RIAÑO, Orlando, ACOSTA, Carlos y LEAL, Robert. Clasificación de una imagen satelital empleando máquinas de soporte vectorial para cuantificar el área de Pinus Patula en una plantación. *Redes de ingeniería* [en línea]. Noviembre 2016. [Fecha de consulta : 02 de mayo del 2020], Disponible en:
<https://revistas.udistrital.edu.co/index.php/REDES/article/view/11991/12620> ISSN: 2248-762X.
88. ROPLIFE. Impacto del cambio climático en la incidencia de plagas y enfermedades de los cultivos .Universidad Nacional De Colombia, 2015 Quiroga Angelica [en línea] [Fecha de consulta :16 de marzo del 2020]. Disponible en :
<https://www.croplifela.org/es/actualidad/articulos/impactos-del-cambio-climatico-en-la-incidencia-de-plagas-y-enfermedades-de-los-cultivos>
89. RULLAN, Cristóbal. Aplicación de la teledetección satelital en el seguimiento de la defoliación por insectos forestales. Tesis (Doctor en Agronomía). Palencia: Universidad de Valladolid, 2015. Disponible en:
<http://uvadoc.uva.es/handle/10324/16199>
90. RUMPF, T., MAHLEIN, A.-K., STEINER, U., OERKE, E.-C., DEHNE, H.-W., y PLÜMER, L. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computer and Electronics in Agriculture* [en línea], octubre del 2010, vol. 74, N°. 1, págs. 91–99. [Fecha de consulta : 02 de mayo del 2020] Disponible en: doi: 10.1016/j.compag.2010.06.009
<https://www.sciencedirect.com/science/article/pii/S0168169910001262>
91. SABAH, Bashir y NAVDEEP, Sharma. Remote Area Plant Detection Using Image Processing. *IOSR Journal of Electronic and Communication Engineering* [en línea]. Septiembre - octubre 2012, vol. 2, n°.6. [Fecha de consulta : 15 de mayo del 2020] Disponible en:
<https://pdfs.semanticscholar.org/704a/00ab9941390b24f1af4951b89495dc9c0078.pdf> ISSN: 2278-2834
92. SANCHEZ, Arely y ARGUIJO, Simón. Análisis de imágenes multiespectrales para la detección de cultivos y detección de plagas y

- enfermedades en la producción de café. *Investigación en Ciencias de la Computación* [en línea]. 2018, Vol,147, n°. 7. [Fecha de consulta : 15 de mayo del 2020] Disponible en: https://www.cicling.org/micai/rcs-local/2018_147_7/Analisis%20de%20imagenes%20multiespectrales%20para%20la%20deteccion%20de%20cultivos%20y%20deteccion%20de%20plagas.pdf. ISSN 1870-4069.
93. SANDHU, G. K, Y KAU, R. Plant disease detection techniques: a review. 2019 *International Conference on Automation, Computational and Technology Management (ICACTM)* [en línea]. 29 de junio del 2019 [Fecha de consulta : 06 de mayo del 2020] Disponible en: <https://ieeexplore.ieee.org/abstract/document/8776827>
94. SERRANO, Jorge, FÀBREGA, José, QUIROZ, Evelyn, SANCHEZ, Galán, y JIMENEZ, José. Análisis prospectivo de la detección hiperespectrales de cultivos de arroz (*Oryza sativa* L.). In *6th Engineering, Science and Technology Conference* [en línea]. 11 de febrero del 2018, págs. 69-79. [Fecha de consulta : 10 de mayo del 2020] . Disponible en: DOI 10.18502/keg.v3i1.1414. <https://knepublishing.com/index.php/KnE-Engineering/article/view/1414>
95. Shivani K. Tichkule ; Dhanashri. H. Gawali, Plant diseases detection using image processing techniques, 2016 Online International Conference on Green Engineering and Technologies (IC-GET) [en línea]. 04 May 2017. [Fecha de consulta : 14 de junio del 2020] . Disponible en: <https://ieeexplore.ieee.org/document/7916653>
96. TAM, Jorge, VERA, Giovanna y OLIVEROS, Ricardo. tipos, métodos y estrategias de investigación científica. *Pensamiento y acción* [en línea].2008, vol. 5,págs. 145-154. [Fecha de consulta : 29 de mayo del 2020] . Disponible en: http://www.imarpe.pe/imarpe/archivos/articulos/imarpe/oceanografia/adj_model_a_pa-5-145-tam-2008-investig.pdf
97. TIAN, Y., WANG, L. Y ZHOU, Q. Grading Method of Crop Disease Based on Image Processing. *IFIP International Federation for Information Processing*. [en línea]. 2012, págs. 427-433. [Fecha de consulta : 02 de mayo del 2020] Disponible en: doi: 10.1007/978-3-642-27278-3_45.

https://link.springer.com/chapter/10.1007/978-3-642-27278-3_45

ISBN978-3-642-27278-3

98. UREA, Carolina, ESPINOZA, Adriana y Urea, Elizabet. El control de las plagas agrícolas pasado presente y futuro. *Ciencia, México* [en línea]. Julio - setiembre 2014, vol 65, n°. 3, págs. 78-87. [Fecha de consulta : 15 de Abril del 2020] Disponible en: <https://biblat.unam.mx/es/revista/ciencia-academia-mexicana-de-ciencias/articulo/el-control-de-plagas-agricolas-pasado-presente-y-futuro> ISSN: 1405-6550
99. VILLALVA, Sonia. Plagas y enfermedades en jardines[en línea]. Madrid: Graficas Rogar, 2012. 3ª edición. ISBN 9788484764397. Disponible en: <http://www.books.google.com>
100. VELÁZQUEZ, Noe, SASAKI, Yutaka, NAKANO, Kazuhiro, MEJÍA, José y ROMANCHIK, Eugenio. Detección de cenicilla en rosa usando procesamiento de imágenes por computadora. *Revista Chapingo Serie Horticultura* [en línea]. 17 de junio del 2011, vol.17, n°.2. págs. 151-160. [Fecha de consulta : 06 de mayo del 2020] Disponible en: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1027-152X2011000200008
101. WANG P, JIA GH y ZHOU Z Y. Algoritmo de segmentación de agrupación difusa GK mejorado para puntos dañados por arroz infestados por Rice Leaf Roller. *Int J Precis Agric Aviat* [en línea]. 2019, vol. 2, n°2, págs. 62–66. [Fecha de consulta : 25 de junio del 2020] Disponible en: <http://www.ijpaa.org/index.php/ijpaa/article/view/51>
102. WANG, W., LI, C., TOLLNER, E. W., GITAITIS, R. D., Y RAINS, G. C. Shortwave infrared hyperspectral imaging for detecting sour skin (*Burkholderia cepacia*)-infected onions. *Journal of Food Engineering* [en línea]. mayo – octubre 2011, vol. 109, n°.1, págs. 38-48. [Fecha de consulta : 06 de mayo del 2020] Disponible en: Doi: 10.1016/j.jfoodeng.2011.10.001. <https://www.sciencedirect.com/science/article/abs/pii/S0260877411005292>
103. YUAN, L., BAO, Z., ZHANG, H., ZHANG, Y., & LIANG, X. Habitat monitoring to evaluate crop disease and pest distributions based on multi-source satellite remote sensing imagery. *Optik* [en línea]. 2017, vol. 145, págs., 66–73.

- [Fecha de consulta : 15 de junio del 2020]. Disponible en: https://www.researchgate.net/publication/318009675_Habitat_monitoring_to_evaluate_crop_disease_and_pest_distributions_based_on_multi-source_satellite_remote_sensing_imagery
104. ZHANG, J.; PU, R.; HUANG, W.; YUAN, L.; LUO, J.; WANG, J. Uso de datos hiperespectrales in situ para detectar y discriminando la enfermedad del óxido amarillo del estrés nutricional. *Cultivos de campo Res.* 2012, vol. 134, págs. 165–174.
105. ZHANG, J., YUAN, L., WANG, J., HUANG, W., CHEN, L., y ZHANG, D. Spectroscopic Leaf Level Detection of Powdery Mildew for Winter Wheat Using Continuous Wavelet Analysis. *Journal of Integrative Agriculture* [en línea]. Setiembre 2012, vol. 11, n°.9, págs. 1474–1484. [Fecha de consulta : 15 de mayo del 2020]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S2095311912601476>
106. ZHENG, Q., HUANG, W., CUI, X., SHI, Y., & LIU, L. New Spectral Index for Detecting Wheat Yellow Rust Using Sentinel-2 Multispectral Imagery. *Sensors* [en línea].2018,vol. 18, N°, 3, pag 868. [Fecha de consulta : 15 de junio del 2020]. Disponible en: doi:10.3390/s18030868
107. ZUÑIGA, Juan. Aplicación de sensores remotos para análisis del estado vegetativo del cultivo de palma de aceite por medio de Índices de Vegetación de Diferencia Normalizada (NDVI) y firmas espectrales mediante fotografías aéreas. Especialización en Geomática. Bogotá D. C: Universidad Militar Nueva Granada, 2018. Disponible en: <https://repository.unimilitar.edu.co/bitstream/handle/10654/20387/Zu%C3%B1igaLopezJuanManuel2018.pdf?sequence=1&isAllowed=y>

ANEXOS

ANEXO 1. Ficha de recolección de datos

		FICHA DE RECOLECCION DE DATOS	
TITULO:			
PAGINAS UTILIZADAS:		AÑO DE PUBLICACION <input type="text"/>	LUGAR DE PUBLICACION <input type="text"/>
TIPO DE INVESTIGACION:		AUTOR (ES):	
OBJETIVOS:			
PALABRAS CLAVES:			
PLANTA:		DAÑOS:	
ENFERMEDAD Y/O PLAGA:			
METODO DE OBTENCION DE IMAGEN:			
SATELITE:		IMAGENES:	
TECNICAS DE PROCESAMIENTO DE IMAGEN:			
INDICES DE VEGETACION:			
ALGORITMOS:			
RESULTADOS:			
CONCLUSIONES:			