



Universidad
Señor de Sipán

**FACULTAD DE INGENIERIA,
ARQUITECTURA Y URBANISMO
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

TESIS

**Detección automática de la enfermedad lasiodiplodia del
palto utilizando imágenes digitales con Máquinas de
Soporte de Vectores**

**PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS**

Autor:

**Bach. Sigueñas Icanaque Jack
Brayan**

ORCID: <https://orcid.org/0009-0001-4607-7439>

Asesor:

**Dr. Tuesta Monteza Victor
Alexci**

ORCID: <https://orcid.org/0000-0002-5913-990X>

Línea de Investigación

**Ciencias de la información como herramientas multidisciplinares y
estratégicas en el contexto industrial y de organizaciones**

Sublínea de Investigación

**Nuevas tendencias digitales orientadas al análisis y uso estratégico
de la información**

**Pimentel – Perú
2024**

**DETECCIÓN AUTOMÁTICA DE LA ENFERMEDAD LASIODIPLDIA DEL PALTO
UTILIZANDO IMÁGENES DIGITALES CON MÁQUINAS DE SOPORTE DE VEC-
TORES**

Aprobación del jurado:

Dr. Tuesta Monteza Víctor Alexci

Presidente del Jurado

Mg. Arcila Diaz Juan Carlos

Secretario del Jurado

Mg. Asenjo Carranza Enrique David

Vocal del Jurado

sigueñas Icanaque

Detección automática de la enfermedad lasiodiplodia del palto utilizando imágenes digitales con Máqu

My Files

My Files

Universidad Señor de Sipan

Detalles del documento

Identificador de la entrega

trn:oid:::26396:410306706

Fecha de entrega

28 nov 2024, 12:39 p.m. GMT-5

Fecha de descarga

28 nov 2024, 12:44 p.m. GMT-5

Nombre de archivo

tesis final-turnitin.docx

Tamaño de archivo

6.1 MB

68 Páginas

11,268 Palabras

60,659 Caracteres



Página 2 of 75 - Descripción general de integridad

Identificador de la entrega trn:oid:::26396:410306706

22% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 8 palabras)

Fuentes principales

21% Fuentes de Internet

4% Publicaciones

11% Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Caracteres reemplazados
14 caracteres sospechosos en N.º de páginas
Las letras son intercambiadas por caracteres similares de otro alfabeto.

Texto oculto
85 caracteres sospechosos en N.º de páginas
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



DECLARACIÓN JURADA DE ORIGINALIDAD

Quien(es) suscribe(n) la DECLARACIÓN JURADA, soy(somos) **egresado (s)** del Programa de Estudios de **Ingeniería de Sistemas** de la Universidad Señor de Sipán S.A.C, declaro (amos) bajo juramento que soy (somos) autor(es) del trabajo titulado:

DETECCIÓN AUTOMÁTICA DE LA ENFERMEDAD LA SIDIPLODIA DEL PALTO UTILIZANDO IMÁGENES DIGITALES CON MAQUINAS DE SOPORTE DE VECTORES

El texto de mi trabajo de investigación responde y respeta lo indicado en el Código de Ética del Comité Institucional de Ética en Investigación de la Universidad Señor de Sipán, conforme a los principios y lineamientos detallados en dicho documento, en relación con las citas y referencias bibliográficas, respetando el derecho de propiedad intelectual, por lo cual informo que la investigación cumple con ser inédito, original y autentico.

En virtud de lo antes mencionado, firman:

Sigueñas Icanaque, Jack Brayan	DNI: 76734340	
---------------------------------------	---------------	--

Pimentel, 06 de junio de 2023.

Dedicatoria

Agradecer a Dios y mis padres por guiar mis pasos para cumplir mi meta trazada, con esfuerzo y humildad, sin ellos no hubiese sido posible, sé que no es fácil pero tampoco imposible lograr lo que más quería culminar mi carrera profesional de ingeniería de sistemas todo sacrificio tiene su recompensa, al Dr. Víctor Alexci Tuesta Monteza que me ayudo y guio durante el proceso, al Mg. Heber Ivan Mejía Cabrera por incentivar me con el tema de investigación, agradecido por compartir sus conocimiento, enseñanzas para poder ser un profesional de éxito.

Jack!

Índice

I. INTRODUCCIÓN	9
1.1. Realidad problemática.....	9
1.2. Trabajos Previos	12
1.3. Formulación del problema	18
1.4. Hipótesis	18
1.5. Objetivos	18
1.6. Teorías relacionadas al tema	19
II. MATERIALES Y MÉTODO	50
2.1. Tipo y Diseño de Investigación.....	50
2.2. Variables, Operacionalización	50
2.2.1. Variable independiente	50
2.2.2. Variable dependiente	50
2.2.3. Operacionalización de la variable	51
2.3. Población de estudio, muestra, muestreo y criterios de selección	53
2.3.1. Población	53
2.3.2. Muestra	53
2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad ...	53
2.5. Procedimiento de análisis de datos	54
2.6. Criterios éticos.....	55
III. RESULTADOS Y DISCUSIÓN	56
3.1. Resultados	56
3.2. Aporte de la investigación (opcional).....	59
V. CONCLUSIONES Y RECOMENDACIONES	76
4.1. Conclusiones	76
4.2. Recomendaciones	76
REFERENCIAS	77
ANEXOS	80

Resumen

En esta investigación se ha propuesto detectar la enfermedad lasiodiplodia del palto en imágenes digitales utilizando máquinas de soporte de vectores. El cultivo del palto presenta una variedad de enfermedades causadas por hongos afectando a la producción. Se realiza la adquisición de imágenes en 2 partes: la primera parte es siguiendo un protocolo, que mide la distancia, las imágenes capturadas con enfoque automático y la apertura de la cámara, en la segunda parte es el diseño de adquisición en el campo realizándose de la siguiente manera: se logró visualizar que los síntomas se manifiestan en tallos, por lo que se tomaron las imágenes sobre ellos, dividiendo esta adquisición en tallos sanos y tallos enfermo. En la construcción de la base de datos se utilizó un repositorio de imágenes, el número consideradas en total ha sido de 150 imágenes, entre las cuales las muestras que fueron tomadas están con defecto y sin defecto. Para caracterizar a la enfermedad lasiodiplodia se consulta a expertos. En el procesamiento se procedió a redimensionar las imágenes y estandarizarlas, se realizó un pre-procesamiento para poder quitar partes que no eran necesarias al momento del procesamiento retirando el fondo de las imágenes. El método en esta investigación está basado en visión computacional para realizar la clasificación automática de la enfermedad lasiodiplodia en la parte de segmentación se implementó dos métodos: Otsu y histograma en hsv para entrenar la técnica de clasificación automática de máquinas de vectores de soporte (SVM), se utiliza los vectores de características de color. obteniendo como resultado la precisión, sensibilidad, severidad en la clasificación. Los resultados experimentales dieron una precisión de 100% lo que sugiere que SVM se puede utilizar para la detección de lasiodiplodia en palto.

Palabras Clave: Detección automática, lasiodiplodia, SVM, histograma en hsv, otsu.

Abstract

In this research it has been proposed to detect the disease lasiodiplodia of the avocado in digital images using vector support machines. The culture presents a variety of diseases caused by fungi affecting production. the acquisition of images in 2 parts is carried out: the first part is following a protocol that is the distance, the images captured with automatic focus, the opening of the camera, in the second part is the acquisition design in the field was carried out in the following way: it was possible to visualize that the symptoms are manifested in stems, so the images were taken on them, dividing this acquisition into healthy stems and diseased stems. In the construction of the database a repository of images was used, the number considered in total has been 150 images, among which the samples that were taken are defective and without defect. To characterize the disease lasiodiplodia experts are consulted. In the processing, images were resized and standardized, pre-processing was performed in order to remove parts that were not necessary at the time of processing by removing the background of the images. The method in this investigation is based on the computational vision to perform the automatic classification of the disease lasiodiplodias in the part of the segmentation is investigated two methods: otsu and histogram in hsv to train the technique of automatic classification of support vector machines (SVM) The color characteristics vectors are used. Obtaining as result the precision, sensitivity, severity in the classification. The experimental results gave a precision of 100% suggesting that SVM can be used for the detection of lasiodiplodia in avocado.

Keywords: Automatic detection, lasiodiplodia, SVM, histogram in hsv, otsu.

I. INTRODUCCIÓN

1.1. Realidad problemática.

El aguacate es una fruta con una tendencia de producción cada vez mayor, debido a la gran demanda en el mercado global. Actualmente, los aguacates se producen en su totalidad en regiones tropicales y subtropicales del planeta tierra, el logro de su producción supera fácilmente los 3 millones de toneladas por periodo, en más de 400.000 hectáreas de tierra cultivada, según registro de la FAO. El país que más produce y exporta en el mundo es México, Perú ocupando el séptimo lugar en producción en 2007 e igual lugar en exportaciones en 2005.

Según cifras proporcionadas por la “ONU” la Agricultura y la Alimentación” (FAOSTAT) y que corresponden al año 2012, la producción mundial de esta fruta ha mostrado una tendencia creciente durante el período 2000-2012. En los primeros años de la última década participó con más del 33% de la producción mundial, en los años siguientes ha mantenido un comportamiento oscilante, pero con una tendencia ligeramente decreciente, de manera que en 2012 mostró una participación del 30%.

Fig. 1. Producción Mundial de palta (Aguacate) (Miles t) [2]

Países	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012
Mundo	2 707	2 786	2 950	3 174	3 216	3 420	3 658	3 613	3 444	3 969	3 898	4 277	4 360
Mexico	907	940	901	905	987	1,022	1,134	1,143	1,162	1,231	1,107	1,264	1,316
Indonesia	146	142	238	256	222	228	239	202	244	258	224	276	294
Rep. Dominicana	82	111	148	274	219	113	216	183	188	184	289	295	290
EE.UU.	217	203	181	212	163	283	247	193	105	271	158	239	245
Colombia	132	137	143	163	171	172	192	194	184	189	205	215	219
PERÚ	84	93	94	100	108	103	113	122	136	157	184	213	215
Kenya	52	54	52	71	80	100	104	94	104	145	202	201	186
Chile	98	110	140	140	160	160	205	210	123	232	166	156	160
Brazil	86	154	174	157	171	169	164	154	147	139	153	160	160
Rwanda	8	15	20	30	40	50	60	70	79	141	130	143	145
Rep. Pop. China	70	75	75	81	100	125	90	92	95	100	102	109	110
Guatemala	26	27	47	66	59	59	117	114	96	99	94	91	95
South Africa	69	69	67	77	57	106	61	65	84	77	83	76	92
Venezuela	52	44	50	46	52	63	59	83	72	75	73	82	83
España	64	75	74	77	76	75	80	82	74	72	97	83	77
Israel	81	79	94	59	73	86	85	86	53	85	70	75	73
Camerum	50	51	52	54	53	54	55	53	55	54	56	70	72
Congo	63	61	60	61	62	63	63	64	65	66	67	68	70
Marruecos	13	14	14	15	16	13	16	17	19	26	34	34	54
Haiti	45	42	51	51	47	54	54	58	45	44	49	52	53
Otros países	362	290	275	280	300	322	302	334	314	324	353	375	350

Perú, es importante resaltar su continuo crecimiento, que se ubicó como el sexto país productor de aguacate en el mundo, en el año 2000 ocupaba el séptimo.

El 2012 se calculó un crecimiento de 90.000 mil has , al 2016 en 200.000 mil has de superficie sembrada, lima en el primer lugar con un 33%, la libertad el 21%, Junín un 19%, Ayacucho el 11%, Ica un 4%, el 3%(Ancash y Cajamarca), un 2% para Moquegua, Arequipa y Cusco[3].

Aproximadamente el 25% de la producción mundial de aguacate se exporta. La producción total de cítricos en los Estados Unidos representó el 65%, mientras que California produjo el 32% y Texas y Arizona produjeron el 3% [4]. El cultivo presenta una variedad de enfermedades causadas por hongos afectando a la producción, para obtener el recojo de síntomas en el planto se utiliza imágenes digitales.

Las enfermedades causadas por hongos pueden provocar daños enormes en rentabilidad y la calidad de la cabeza y también pueden reducir la vida útil de las plantas[5].

El hongo se caracteriza por presentar un micelio gris con numerosas esporas o conidios, que se desprenden de los conidióforos y se dispersan principalmente por el viento y, en segundo lugar, por el agua. El hongo sobrevive a través de estructuras de resistencia, formadas por compactación de milesio llamados esclerocios, que son de color negro y pueden sobrevivir largos períodos en el suelo.[12].

La agricultura de precisión para procesamiento e imágenes espectrales y de infrarrojo cercano, para la detección temprana de enfermedades en imágenes digitales, calcula varios índices de vegetación, como clorofila, índices fotoquímicos y estructurales.

El método para el descubrimiento de plagas en las plantas es la observación, pero este tipo de método tiene un gran inconveniente, que muchas veces se asocia con el hecho de que este tipo de observación o selección es realizada por un observador experto en el campo. [7] nos informa que el principal obstáculo de este suceso es que al final la evaluación visual siempre está sujeta a una persona experimentada. Obviamente, estos tipos de métodos consumen mucho tiempo y también requieren personal experimentado.

Como resultado, existe la necesidad de que los ingenieros desarrollen nuevos métodos de descubrimientos automatizados y nuevas fórmulas que cumplan con requisitos como sensibilidad, especificidad y confiabilidad para aumentar el descubrimiento del mal de plagas en las plantas.

Los avances de la tecnología satelital facilitan la adquisición de datos históricos de tal forma que sea más extensa y sostenible en cada momento, ahora se ha convertido en un hábito diario el visualizar diversos soportes de información meteorológica o climática desde satélites. Como es sabido que todo objeto o materia emite radiación electromagnética la cual es captada a partir de la energía proveniente del sol, el ojo se limita a detectar solo una pequeña parte de la radiación que se considera luz, incolora, si proviene directamente del sol. Pero cuando la radiación golpea un objeto, se absorben ciertas longitudes de onda y solo una parte se refleja nuevamente, razón por la cual vemos colores [8].

En la década de 1980, las imágenes de Landsat resultaron útiles para detectar los daños causados por las polillas y los gusanos de las piceas en los bosques estadounidenses. Estas imágenes se obtuvieron utilizándolas para detectar el ataque de otros insectos. La aparición de nuevos sensores, la disminución de los costos de obtención de imágenes de mayor resolución y los problemas existentes con Landsat han llevado al uso de nuevas resoluciones (espaciales y espectrales) y nuevos sensores para detectar áreas descubiertas. [9].

En el trabajo de Lucero Carrillo and H. A. Saldaña Saldaña [10], se indica “Las imágenes obtenidas de los satélites se han utilizado para detectar enfermedades en el follaje de los árboles y también para el análisis del cambio de uso de la tierra en áreas agrícolas y forestales”.

Los sensores espectrales se ordenan según su valor espectral, escala espacial y tipo de detector. El espectro visible (de 400 a 700 nm) depende del contenido de pigmentos de las hojas. La reflectividad en la zona del infrarrojo próximo del espectro (NIR de 700 a 1100 nm) depende en gran medida del estado de la hoja, como la evolución de

lanzamiento interno, la morfología de la hoja y la absorción de agua por las hojas. Mientras que la radiación infrarroja de onda corta (de 1100 a 2500 nm) depende de la composición química de las hojas y del agua[7].

Por tanto, es un problema de detección a resolver la enfermedad lasiodiplodia del palto que en su etapa inicial es asintomática se propone la utilización de imágenes multiespectrales RGB que nos arroje resultados rápidos y a gran escala, para que esta enfermedad puede ser tratada a tiempo y así la producción de la palta se vea menos afectada, más provechosa y saludable.

1.2. Trabajos Previos

Vidango-Ponce en 2017 desarrolló el trabajo de investigación "*Implementación de un sistema de procesamiento digital de imágenes para la detección de malezas en el cultivo de quinua*". Universidad Nacional del Altiplano. El principal problema que enfrente es la maleza llamada nabo silvestre o mostaza (*Brassica campestris*), ocasionando el crecimiento del planto de quinua, proponiendo como solución extracción de cultivos, usando drones para capturar imágenes multiespectrales identificando plantas en mal estado. El objetivo general de esta investigación es realizar la detección de malezas mediante el procesamiento digital de imágenes, implementando un sistema fotográfico aéreo para la adquisición de imágenes de cultivo de quinua, determinando la cantidad y posición de la maleza en la quinua por análisis de pixeles por color [6].

DAYANA CECILIA OCAMPO ZEGARRA en 2014 desarrollo el trabajo de investigación "*Efecto de daño mecánicos en post cosecha y contenido de materia seca en la calidad de post cosecha de frutos de palta*". Universidad Católica de Santa María. El principal problema que enfrente son las plagas y las enfermedades como daños físicos, errores de cosecha, esto impide que en el mercado no se puede exportar generando problemas, reclamos en los clientes. El objetivo principal de esta investigación es evaluar el efecto de contenido de materia seca(%MS) y de daños mecánicos en la cosecha por golpes, sobre la calidad post cosecha de frutos de palta de exportación (*Persea americana* cv. Hass), expresada en

manchas oscuras en la epidermis. Los resultados que se obtuvieron de materia seca, en paltas sin virar y con varamiento, observándose que, de un total de 14 muestras para cada una de ellas, en promedio para paltas sin virar de 23.25% y para paltas viradas de 28.79%[7].

PUCE en 2018 desarrollo el trabajo de investigación “*Diagnostico automático de roya amarilla en hojas de cafeto aplicando técnicas de procesamiento de imágenes y aprendizaje de maquina*”. Pontificia Universidad Católica del Perú. El principal problema que enfrente es la roya amarilla, una de las enfermedades más peligrosas y serias que atacan a los cultivos del cafeto, siendo la más conocida y de entre todas las enfermedades de las plantas tropicales, no solo afecta la cantidad de producción, sino la calidad del cultivo, lo que se traduce en millonarias pérdidas económicas. El objetivo principal de esta investigación es desarrollar un modelo algorítmico que permita automatizar el proceso de diagnóstico de roya amarilla en hojas de cafeto, de tal forma que detecte cuando una hoja está o no infectada, y en caso lo estuviese, calcular el grado de severidad del hongo. Los resultados que se obtuvieron para poder comparar de manera equitativa los métodos, se escogió clustering el que fue producto del cambio de espacio de colores a luv, se mostró un resultado más preciso respecto al método manual. El resumen de los resultados obtenidos en la comparación de ambos métodos: error promedio thresholding de 8.92% y para error promedio k-means de 17.52%[8].

Palma en 2017 desarrollo el trabajo de investigación “*Detección temprana del potato yellow vein virus en cultivo de solanum tuberosum L. mediante la teledetección*”. Universidad Ricardo Palma. El principal problema que enfrente es el virus PYVV que puede ser transmitido a través de su vector natural (mosca blanca trialeurodes vaporariorum) y de forma vegetativa por tubérculo semilla, provenientes de plantas que expresan síntomas, se pueden obtener plantas que no expresan síntomas y viceversa, en el cultivo de papa esta situación es impredecible y aumenta los riesgos de utilizar tubérculos-semilla infectados y sus posteriores efectos para la producción. El objetivo principal de esta investigación es determinar la presencia del virus potato yellow vein virus (PYVV) en cultivos de papa mediante la técnica de teledetección. Los resultados que se obtuvieron de las 150 plantas de papas evaluadas, en 35 de ellas se

confirmó la presencia de los virus más importantes que afectan el cultivo de papa, tanto en las plantas infectadas con PVV como en el tratamiento control de cada variedad[9].

Lucero Carrillo & Saldaña Saldaña en 2016 desarrollaron el trabajo de investigación "*Utilización de técnicas de visión artificial para la detección automática de defectos externos del mango*". Universidad Señor de Sipán. El principal problema que enfrento es la dificultad que se presentan el proceso de evaluación del estado de los mangos. El objetivo principal de esta investigación es detectar automáticamente defectos externos del mango utilizando técnicas de visión artificial. Los resultados que se obtuvieron con el método de segmentación Otsu y usando K-NN un porcentaje de acierto global de 91.66%, mientras que con la red neuronal de 83.33% de acierto global. En los resultados se obtuvo los mejores valores al clasificar con K-NN, logrando una precisión de 84%, revocación de 91% y valor-F de 87%, usando la red neuronal se obtuvo una precisión de 83%, revocación de 83% y un valor-F de 83%. Los resultados obtenidos utilizando GLCM con el método de segmentación Otsu y K-NN se obtuvo un porcentaje de acierto global de 91.66%, al igual con la red neuronal un 91.66% de acierto global. Se obtuvo los mejores valores al clasificar con K-NN, logrando una precisión de 84%, revocación de 91% y valor-F de 87%, usando la red neuronal una precisión de 84%, revocación de 91% y un valor-F de 87%[10].

Detection and Classification of Diseases of Grape Plant Using Opposite Colour Local Binary Pattern Feature and Machine Learning for Automated Decision Support System

Harshal Waghmare, Radha Kokare en 2016, los autores mencionaron en su artículo que en la hoja de la planta de uvas procedimiento de detección de la afección, el procedimiento toma una única hoja de una planta como una inclusión y la segmentación se lleva a cabo posteriormente de la eliminación de fondo la litografía de la hoja segmentada se analiza luego a través de filtro de paso alto para detectar la parte enferma de la hoja. La textura de la capa segmentada se recupera utilizando la función de la textura fractal baso única, las características basadas en fractales son localmente invariante en la clase y, por lo tanto, proporciona un buen modelo textura, la textura de cada afección variable será singular, el

patrón de textura extraída se clasifica utilizando multiclase SVM. Las principales enfermedades comúnmente observados en la uva de las plantas que son mildiu y pudrición de negro. Como resultados del algoritmo propuesto de hojas de uva muestra que la integración de técnicas multiclase SVM de procesamiento con DSS en la precisión clasifica enfermedades de plantas de uvas entre hoja sanas y enfermas de manera eficiente[11].

Spectral Mixture Analysis Based Citrus Greening Disease Detection Using Satellite Image of Florida Han Li, Won Suk Lee, Ku Wang en 2013, indicaron que en la actualidad, debido al máximo y menos costoso en comparación con hiperespectrales aéreas (Sa) y imágenes multiespectrales (MS). En primer punto, se utilizó el índice de vegetación de diferencia normalizada (NDVI) para eximir plantaciones de cítricos de otra vegetación natural. Dos métodos de obtención endmember desiguales, vértice análisis de componentes (VCA) y iterado constreñido detección de endmember (ICE) se utilizaron para separar endmember para el suelo, hierba, HLB infectado arboles cítricos, y árboles de cítricos sanos de candidatos endmember identificados de una imagen Landsat 5 thematic mapper(Tm) con la ayuda de una litografía de worldview-2. Se utilizaron como una acogida de test espectral mezcla múltiple endmember (Mesma), con el final de ceder el mapa fracción de los arboles cítricos. Los resultados fueron comparados y evaluados, demostrando que hay un gran potencial para el enverdecimiento de cítricos detectando la enfermedad mediante una imagen de satélite[4].

Digital Image Processing Technique for Palm Oil Leaf Disease Detection Using Multiclass SVM Classifier Ahmad Nor Ikhwan Masazhar, Mahanijah Md Kamal en 2017, indicaron en el artículo que el trabajo presenta el uso de la técnica de procesamiento de imagen digital para la detección y clasificación de los síntomas de la enfermedad de la hoja de palma de aceite utiliza k-medias de coalización y clasificador SVM multiclase para resolver dos enfermedades de aceite de palma en base a los signos de la enfermedad a través de la hoja. Mediante el uso de técnica de agrupación de k-medias, trece tipos de características se extraen de la imagen de las hojas. La clasificación de la enfermedad se lleva a cabo a través del uso de clasificador SVM multiclase[12].

Computer Vision Based Approach to Detect Rice Leaf Diseases Using Texture and Color Descriptors Bhagyashri S. Ghyar, Gajanan K. Birajdar en 2017, indicaron que en el artículo su objetivo es desarrollar un sistema automático basado en visión por computadora para el diagnóstico de enfermedades causadas por plagas en las plantas de arroz, por medio del enfoque de visión computacional implica tres elementos de extracción de características en este experimento, la área enferma de la hoja, descriptores de textura usa una matriz de co-ocurrencia de grado gris (GlcM) y los tiempos de color se extraen de enfermos y imágenes no enfermas dando como resultado un vector de características 21-d. genético, el tratamiento de selección de características de vector reduce la complejidad. Neural artificial la red (Ann) y la máquina de vectores de soporte (SVM) se utiliza para la clasificación. El resultado del algoritmo propuesto en clasificación de precisión es de 92.5% usando SVM y un 87.5% para Ann[13].

Detection of Leaf Diseases and Classification using Digital Image Processing R.Meena Prakash, G.P.Saraswathy, G.Rokshmi, K.H.Mangaleswari, T.Kaviya en 2017, indicaron que en este trabajo es poner en práctica técnicas de análisis de imagen y de clasificación para detectar enfermedades de la hoja. El enfoque propuesto consta de cuatro partes. (1) imagen de procesamiento previo, (2) segmentación de la hoja usando k-means clustering para evaluar áreas enfermas, (3) extracción de características y (4) clasificación de enfermedades. Las características de textura se extraen utilizando característica estadística de niveles de gris co-ocurrencia matriz (GlcM) y la clasificación se realiza utilizando máquinas de soporte de vectores(SVM). El resultado de las partes enfermas de las hojas se clasifica en hojas enfermas y no enfermas utilizando SVM, cambiando el tamaño de la imagen de entrada de 256x256 y se convierte en escala de grises. Las características de textura GlcM se extraen y se almacenan todas las imágenes en la base de datos dando como entrada al clasificador, la base de datos se divide aleatoriamente en vectores de entrenamiento y prueba dejando una clasificación de exactitud de 0.90[14].

An Automated Approach for Clasification of Plant Diseases Towards Development of Futuristic Decision Support System in Indian Perspective Yogesh Dandawate, Radha

Kokare en 2015, indicaron que el artículo se centra basado en el procesamiento de imágenes para la detección de enfermedades de plantas de soja, las imágenes son capturadas usando la cámara móvil que tiene una resolución mayor a 2 mega pixeles, el objetivo del proyecto propuesto es proporcionar insumos para el sistema de soporte de decisiones(DSS), que está desarrollado para dar asesoramiento a los agricultores a medida que se requiere a través de internet móvil, el trabajo propuesto clasifica las imágenes de hojas de soya sanas y enfermas usando máquinas de soporte de vectores(SVM), el algoritmo se compone en cuatro pasos principales: adquisición de la imagen, la extracción de la hoja de fondo complejo, análisis estadísticos y clasificación, la etapa de Pre-procesamiento incluye la conversión de RGB a espacio de color HSV(valor de saturación de tono), para la extracción de la región de interés (ROI) de la imagen original, se utiliza umbrales múltiples, los métodos basados en la base de color y de racimo se utilizan para la segmentación. El algoritmo utiliza transformación de característica invariante de escala (SIFT) que reconoce automáticamente las especies de plantas en base a la forma de la hoja. SVM demuestra la capacidad automática y precisa a la clasificación de las imágenes. Como resultado final se concluye que este enfoque puede clasificar las hojas con una precisión media de 93.79%[15].

Plant Disease Identification: A Comparative Study Shriroop C. Madiwalar, Medha V.

Wyawahare en 2017, indicaron que en el artículo se ha propuesto la identificación de enfermedades de las plantas utilizando imágenes en color de hojas de mango, este punto de vista incluye el uso de Ycbcr convirtiendo la imagen y creando un vector de características de textura y el color de las imágenes de entradas al clasificador durante la fase de prueba. Glcm, la técnica basada en color y filtros de gabor utilizado para la extracción de características de textura y color. Los resultados obtenidos utilizando el clasificador de distancia mínima y el uso de máquinas de vectores de soporte (SVM) se hizo, el análisis de técnicas de extracción de característica para obtener resultados individuales para cada técnica el 79.16% y 83.34%

para el clasificador de distancia mínima y la máquina de vectores de soporte sobre una base de datos de 86 imágenes[16].

Empirical Analysis of SIFT, Gabor and Fused Feature Classification Using SVM for Multispectral Satellite Image Retrieval Chandani Joshi, Saurabh Mukherjee en 2017, los autores mencionaron en su artículo que ambos descriptores de características se fusionan para recuperar los resultados con mas tasa de precisión, el experimento se llevó a cabo en imágenes de satélite multiespectrales, del sensor Landsat 8. La precisión y recuperación para el conjunto de datos se calcula. Como resultados muestra la tasa de recuperación mejorada, utilizando el clasificador SVM se va ir incrementando aún más la eficiencia de recuperación mediante la clasificación de las imágenes del satélite basada en área urbana, el cuerpo de agua y la vegetación. Los resultados muestran que la técnica de fusión da un mejor resultado y más precisión, se puede obtener utilizando SVM la clasificación del conjunto de datos[17].

I.3 Formulación del problema

¿Hasta qué punto un método basado en máquinas de vectores de soporte puede detectar lasiodiploidía en el aguacate?

I.4 Hipótesis

La técnica de máquinas de soporte de vectores detecta la presencia de la enfermedad lasiodiplodia del palto con un alto grado de precisión.

I.5 Objetivos

Objetivo general

Detectar la enfermedad lasiodiplodia del palto en imágenes digitales con máquinas de soporte de vectores

Objetivos específicos

- a) Construir base de datos de imágenes.
- b) Caracterizar a la enfermedad lasiodiplodia.
- c) Preprocesar las imágenes digitales.

- d) Implementar la técnica de máquinas de soporte de vectores para detectar la presencia de lasiodiplodia.
- e) Evaluar resultados.

I.6 Teorías relacionadas al tema

1.5.1 Bases teóricas científicas

1.5.1.1. Clasificación de enfermedades

13 enfermedades registradas en el mundo, en patología vegetal clasificamos las enfermedades [3], según su forma de aparición, en tres categorías:

- A. Enfermedades esporádicas (E.S.)
- B. Enfermedades endémicas (E.E.)
- C. Enfermedades epidémicas o epifitotica (E.P.)

1.5.1.2. Enfermedades más importantes en el palto

Muerte regresiva: *Lasiodiplodia theobromae* (E.E, E.P) Pudrición de la flor por *Cladosporium*.

Síntomas: Vertilicios florares Cuando está completamente seco, es de color marrón oscuro a negro. Muchas flores afectadas se separan fácilmente del raquis. [3].



Signos: Botrytis cinerea rica en esporas: los conidióforos y conidios del hongo patógeno se producen cuando las axilas de las flores y las flores afectadas se exponen a condiciones de humedad. [3].



Cladosporiu

Epidemiología: Condiciones de alta humedad relativa 95-100% nublado: baja intensidad de luz.

Avocado Sun Blotch “Mancha Solar” (E.S)

Explicación de los patógenos: viroides (virus sin cubierta proteica) que consisten en una cadena circular simple de ácido ribonucleico de 247 nucleótidos con un peso molecular de 80 000. Descrito por primera vez en California (1928) Propagación por inoculación [3].

Síntomas: Aparecen rayas de necrosis de color verde claro, amarillentas o rojizas en las ramas, que se extienden a lo largo de ellas. Pueden aparecer grietas rectangulares (piel de cocodrilo) en el tronco y el árbol puede arquearse o doblarse.

Epidemiología: Los viroides se transportan en los tejidos del huésped y el crecimiento que manifieste obedecerá a la especie, las circunstancias ambientales y posiblemente la cepa del viroide.

Algunos árboles no muestran síntomas, pero los rendimientos se reducen drásticamente.

Los viroides se transmiten por semillas, injertos, tijeras o herramientas de poda. También por contacto entre raíces.

Pudrición de la raíz del palto: *Phytophthora cinnamomi* (E.E, E.p).

Explica que esta es la enfermedad que más afecta negativa y directamente al palto. Esta planta pudre los árboles, las frutas. Las plantas infectadas con *phytophthora* tienden a morir poco después de haber sido infectada[3].

Sintomatología: Las hojas de las plantas afectadas se vuelven más pequeñas y cloróticas. No hay nuevos brotes, y las ramas y ramas comienzan a secarse. Las frutas no alcanzarán su tamaño normal y se secarán en las últimas etapas.

Epidemiología: La transmisión del patógeno también se produce a través del equipo de labranza, el suelo, las raíces infectadas y, en ocasiones, a través de las semillas extraídas de la fruta infectada. La infección ocurre a una temperatura de 21-30°C.

Antracnosis y pudrición del fruto: *Colletotrichum gloesporioides* (E.E).

Es una enfermedad limitante de la fruta causada principalmente por la bacteria de la antracnosis, pero se pueden encontrar otras especies de antracnosis que causan la enfermedad en el mismo cultivo.[3].

Colletotrichum gloesporioides se determina por construir células reproductivas o esporas llamadas conidios que participan en la evolución del contagio de la planta. En época de colonización las plantas, existe un ciclo inicial o biotrófica, donde el hongo se nutre de las células vivas de la planta, y un segundo periodo neurotrófica, en la que se obtienen recursos del ataque a las células vegetales muertas. de patógenos.

Síntomas: Los síntomas aparecen primero en aspecto de exudado gelatinoso, luego aparecieron diminutas lesiones con un diámetro de 1 cm. La apariencia era aceitosa, el color se volvió marrón amarillento, los bordes

se hundieron fácilmente y las lesiones se extendieron a diferentes partes de la fruta.

Marchitez por *Fusarium* causada por tricomas, lesiones por pudrición en tallos, frutos, ramas y ramillas.

Epidemiología: Una epidemia ocurre cuando su temperatura es de 10-30°C, la impregnación relativa es superior al 95%, la temperatura óptima para la germinación de conidias es de 25°C y la lluvia por periodo es de 600-1200 mm.

Ciclo de la enfermedad y epidemiología: La enfermedad ocurre cuando las plantas están bajo estrés hídrico. La tricodiploidía es una enfermedad que puede alojarse provisionalmente y dañar el tejido internamente sin mostrar señales de enfermedad en la planta. Esto ocurre cuando el tejido se vuelve vulnerable al agua, al estrés por nutrientes o al ataque de insectos. Las frutas se infectan con esporas a través de una herida.[3].

Los conidios de *Trichodispora* se forman en hojas muertas, ramitas muertas y frutos podridos y se propagan por el agua y el aire.

1.5.1.3. Enfermedades del fruto

A. Pudrición radicular (*Phytophthora cinnamomi*):

El principal problema de este tipo de frutales es que el hongo provoca la pudrición de la raíz, lo que se traduce en una descomposición gradual del árbol, manifestada por hojas pequeñas, amarillamiento de las hojas, defoliación, necrosis, frutos pequeños y muerte completa en infecciones graves. planta planta[18].

B. Muerte regresiva (*Lasiodiplodia theobromae*).

El síntoma más notorio es la aparición de canchales con exudados grumosos de color blanco de varios tamaños, que se distribuyen vagamente

en los troncos y ramas de los árboles jóvenes y adultos infectados. Se observaron daños en los tallos y ramas, por lo que la corteza se reventó y las ramas infectadas murieron gradualmente.[18].

C. Antracnosis (*Colletotrichum gloesporoides*).

La enfermedad se presenta cuando hay alta humedad relativa y lluvia constante. Estos síntomas aparecen como pequeños puntos negros, que se combinan para hacer que las flores y los frutos pequeños se arruguen, se sequen y mueran [18].

1.5.1.4. Imagen digital

La figura bidimensional son funciones $f(x,y)$ donde x e y simboliza el eje del plano. $f(x,y)$ representa la magnitud o nivel de gris de la imagen en ese punto. Si x e y son reservados y están acotados, la efigie es digital.[19].

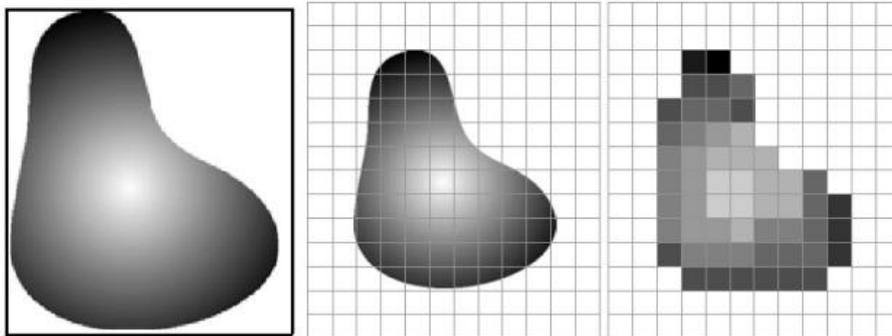


Fig. 2 Nivel de gris de la imagen [19]

- a) Intensidad: La cantidad física que mide la luz presente y que está relacionada con la energía es lo que se cuantifica de 0 a 255 en ocho bits por tono.
- b) Brillo: Debido a la adaptación del ojo, una percepción humana causa relación entre brillo e intensidad no es sencilla.

1.5.1.5. Adquisición de imágenes

El tipo de imágenes que nos interesan son producidas por una combinación de una fuente de "iluminación" y elementos de la escena que reflejan o absorben energía de esa fuente. Recuerde que esta "iluminación" también puede ser un radar, un infrarrojo o una fuente que no sea EEM, como el ultrasonido. Dependiendo de la naturaleza de la fuente de luz, los objetos pueden reflejar o transmitir la energía de la "luz".[20].

a) Iluminación: La cantidad de luz incidente de una fuente de luz en una escena.

b) Albedo: La cantidad de luz reflejada por los objetos en una escena.

una combinación de ambas formas:

$$f(x, y) = i(x, y)r(x, y)$$

F01: Cantidad de luz reflejada

Donde

$$0 < i(x, y) < \infty$$

Y

$$0 < r(x, y) < 1$$

La ecuación establece que la reflectividad varía de 0 (impregnación completa) a 1 (reflexión total). La naturaleza de $i(x,y)$ está definido por la fuente de luz, y la naturaleza de $r(x,y)$ está establecido por las propiedades del objeto. Esto también se aplica al caso en que la imagen se forma por la transmisión de "luz" [20].

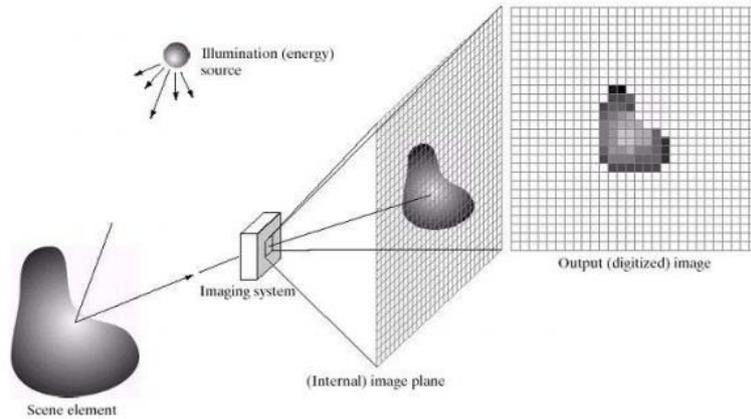


Fig. 3 Ejemplo del proceso de adquisición de una imagen digital [20]

1.5.1.6. Procesamiento digital de imágenes

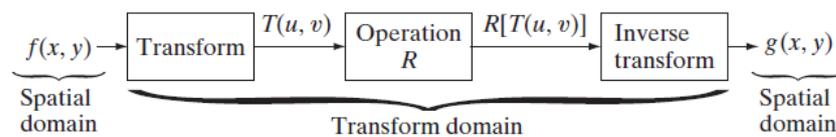
Quizás los primeros intentos de manipular, almacenar e imágenes ocurrieron en la década de 1920, cuando se desarrolló un sistema para transmitir fotografías a través de cables transatlánticos utilizando códigos telegráficos. Este sistema permitía codificar imágenes en 5 niveles de gris, que luego se mejoró a 15 niveles de gris en 1929. El sistema degrada su calidad de la imagen [20].

Si bien todas las configuraciones de proceso de figuración discutidas funcionan exactamente en los píxeles de la imagen anfitriona, esta funciona correctamente en el sometimiento espacial. Cabe indicar que en ciertos casos de procesamiento de imágenes se formulan mejor transformando la imagen de inicio, colocando la tarea en cuestión en el dominio de transformación y aplicando la transformación inversa al dominio espacial. Su particularidad de clase en transformaciones lineales bidimensionales, d,T denotada por (u,v) , puede expresarse en forma general.

$$T(\mathbf{u}, \mathbf{v}) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y)r(x,y,u,v)$$

F02: Transformación lineal bidimensional

donde $f(x,y)$ es la imagen de inicio llamada núcleo de experimento. Evaluar $u=0,1,2,\dots,M-1$ y $v=0,1,2,\dots,N-1$. Como se mencionó anteriormente, X e Y son variables espaciales, mientras que M y N son las dimensiones de fila y columna de f . Las variables u y v se llaman la variable de transformación $T(u, v)$ se llama transformada directa de $f(x, y)$. Dado $T(u, v)$, podemos recuperar $f(x, y)$ usando la transformación inversa de $T(u, v)$,



Para $x=0,1,2,\dots,M-1$ y $Y=0, 1,2,\dots, N-1$, donde $s(x, y, u, v)$ es llamar al núcleo de transformada inversa [21].

1.5.1.7. Pre-procesamiento de imágenes

El preprocesamiento de imágenes para detectar y extraer características requiere un esquema de trabajo que elimine elementos de la imagen que afecten la adquisición de regiones de interés y su posterior procesamiento [20].

Veamos diversos filtros específicos y cómo influye en la imagen:

- a) Un filtro que atenúa las frecuencias altas y transmite las reiteraciones descendentes se llama filtro de paso bajo.
- b) Un colador con las características no común se llama filtro de paso alto. El filtro de paso bajo tiene menos detalle que el filtro original porque las reiteraciones altas están atenuadas. Las imágenes filtradas de paso bajo tienen variaciones de escala de grises menos suaves porque se enfatizan los detalles de la escala de grises de transición [20].

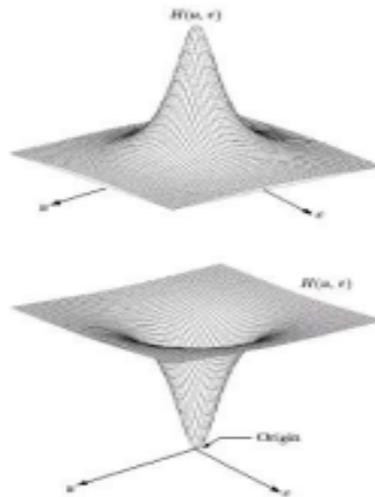


Fig. 4 Filtros pasabajas y pasaaltas [20]

Filtro Bilateral: Un filtro bilateral desenfoca una imagen utilizando una combinación no lineal de valores en la mediana de la imagen conservando los bordes. El método es local, simple e iterativo, combinando colores en base a su proximidad geométrica y similitud fotométrica, con valores cercanos ponderados más que valores lejanos en ambos dominios. La imagen filtrada se obtiene mediante la siguiente ecuación [21]:

$$x_i = \frac{\sum_{j \in N_i} \omega(i, j) x_j}{\sum_{j \in N_i} \omega(i, j)}$$

F03: Filtro no lineal.

donde ω son ponderaciones que es el peso aplicado a cada pixel x_j en el área N_i . Las combinaciones de los pesos de ambas tanto espacial ω_s y la de color ω_c .

$$\omega(i, j) = \omega_s(i, j) \times \omega_c(i, j)$$

F04: Combinaciones de pixel

donde ω_s y ω_c se definen por

$$\omega_s(i, j) = e^{-\frac{(d_s(i, j))^2}{2\sigma_s^2}}$$

$$\omega_c(i, j) = e^{-\frac{(d_c(i, j))^2}{2\sigma_c^2}}$$

F05: Filtro pasa alto, bajo.

Dado que σ_s está relacionado con el radio de la mancha, si σ_s es alto, la mancha será más grande, pero si σ_s es grande, se pueden manchar bordes significativos. σ_c determina cuánto contraste se conserva o se desdibuja. Para valores bajos de σ_c se conservará casi todo el contraste, mientras que para valores altos el comportamiento será un frotis gaussiano lineal [21].

Razones para desarrollar un método de pretratamiento.



Fig. 5 Metodología de preprocesamiento [22].

A. REDUCCIÓN DEL ÁREA DE TRABAJO

Se trata de reducir la imagen a áreas que corresponden a objetos de interés con el fin de reducir el tiempo de procesamiento en pasos siguiente y borra objetos de fondo que no aportan información para el procesamiento.[22].

Recorte automático: Al pasar una imagen binaria con una sola región, determinar los píxeles más externos en las direcciones horizontal y vertical de la región y recortar en el límite se conserva el contenido de la imagen.[22].

B. REDUCCIÓN DE RUIDO

El zumbido es información que no sirve y además contagia la imagen. Esto ocurre mientras la operación y la digitalización, por lo que es imprescindible un método de eliminación de ruido que conserve las características importantes tanto como sea posible [22]. Existen varias técnicas de:

Filtrado de mediana:

Funciona en una imagen cambiando el valor de intensidad de cada píxel analizado de acuerdo con el valor de intensidad promedio del píxel. un vecindario particular. La función primordial del filtrado de mediana es hacer que los puntos con intensidades muy diferentes sean muy similares a sus puntos cercanos y eliminar puntos con intensidades demasiado altas y muy bajas [22]. La función de este filtro se muestra en la figura.

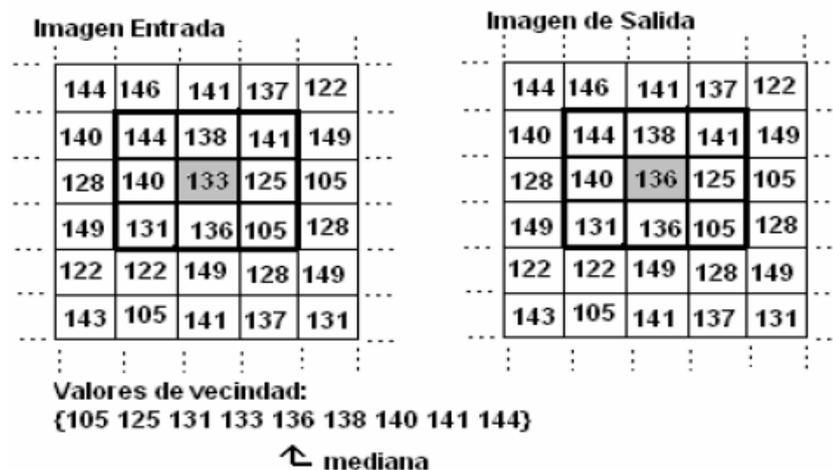


Fig. 6 Funcionamiento filtrado de mediana [22]

Filtrado de Wiener.

Imaginar que la figuración (x,y) está contaminada con Zumbido albo gaussiano $w(x,y)$, necesitamos evaluar la señal $s(x,y)$ de la imagen

contagiada con ruido $a(x,y)$ y pasar el advertencia de ruido, utilizando filtrado lineal adaptativo [22].

$$a(x,y) = s(x,y) + w(x,y)$$

F06: Filtro de eliminación de ruido.

Para la resolución del ejercicio suponga que la señal $s(x,y)$ y el zumbido $w(x,y)$ tienen media cero y son muestras de procesos alternos estacionarios. La valorización lineal s^{\wedge} está definida por la siguiente expresión [22]:

$$\check{S} = a(x,y) \otimes h(x,y)$$

F07: Estimación lineal del error cuadrático.

donde $h(x,y)$ es el estimador del error cuadrático lineal medio

C. REALCE DE CONTRASTE

El conjunto de las imágenes médicas tiene poco contraste y la mamografía no es una excepción. Por lo tanto, es primordial mejorar la trama de estas imágenes antes de su siguiente proceso o análisis. Hay varios métodos para aumentar el contraste, incluyendo:

Técnicas de realce por ampliación del contraste.

La utilización clásica de contraste se basa en una jerarquía de ganancia dada globalmente. Esta función está determinada por un perfil de modificación elegido apropiadamente para lograr la mejora de contraste deseada. Esta técnica mejora el contraste ajustando el histograma, aumentando así lo independizan del nivel de gris entre el fondo y los objetos. [22].

Técnicas de realce por ecualización del histograma.

Esta técnica de construcción de histogramas altera una imagen para que su histograma tenga la forma precisa utilizando un escalado monótono no lineal, que redistribuye los cálculos de magnitud de píxeles de la imagen de inicio para que la imagen de salida tenga un reparto uniforme de magnitud. Conseguir un histograma lo más perfecto posible significa aumentar el rango dinámico de los píxeles. [22].

Técnicas de realce por ecualización adaptativa del histograma.

Es bien sabido que no se puede lograr una buena mejora del contraste cuando solo se usa información global porque los métodos globales introducen efectos de abarrotamiento de intensidad. Para la solución de este problema existe el suavizado de histograma local, o adaptativo, que tiene en cuenta las ventanas locales de cada píxel y va computar el nuevo valor de magnitud en base al histograma parcial definido dada a cada ventana. Además, el suavizado de histograma adaptativo es un operador local colectivo, ya que su totalidad de píxeles de la ventana parcial ayudan por igual a determinar el nuevo valor de píxel central. [22].

Esta clase de filtros actúa directamente sobre los píxeles. Se dividen en filtros lineales (basados en kernel o máscaras de convolución) y filtros no lineales. Un núcleo o máscara de convolución puede entenderse como una matriz de coeficientes que, cuando se aplica a un píxel de destino (piense en un píxel como un punto en el plano (x, y)), logra una transformación del píxel de destino y sus vecinos piensa en la transformación como una imagen $G(x,y)$ [23].

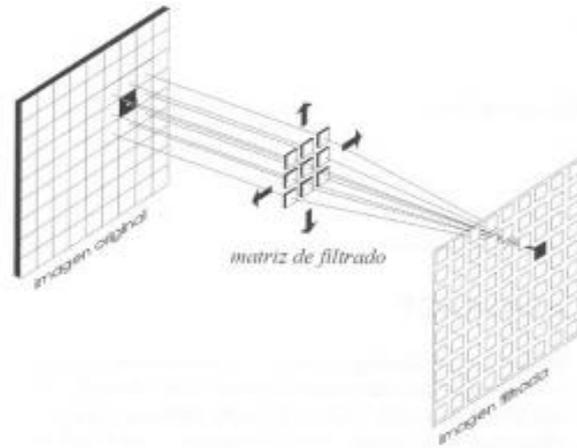


Fig. 7 Filtrado en el dominio del espacio [23]

1.5.1.8. Segmentación

En imágenes digitales, el fraccionamiento viene a ser el proceso de separar o la división de una imagen para demostrar sus subregiones, El elemento parcial u objetos de una manera que facilita su estudio. La segmentación también se puede definir como encontrar regiones de homoprotones y sus límites utilizando algoritmos numéricos [22].

1.5.1.9. Espectro Electromagnético

Una distribución seguida de longitudes de onda y frecuencias desde la longitud de onda bien corta hasta la longitud de onda más larga [24].

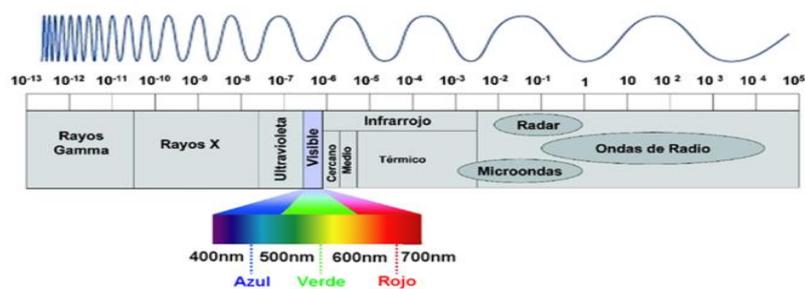


Fig. 8 Clasificación del espectro electromagnético

Fuente: Radio Frecuencia España

Tabla 1 Límites del espectro electromagnético según su división

DIVISION	LIMITES
Rayos Gamma	<0.03nm
Rayos X	0.03–300 nm
Radiación ultravioleta	0.30-0.38 μm
Luz Visible	0.38–0.72 μm
Infrarrojo cercano	0.72–1.30 μm
Infrarrojo medio	7.0–1,000 μm (1 mm)
Radiación microondas	1 mm–30 cm
Ondas de Radio	\geq 30 cm

Fuente: Introduction to Remote Sensing Fift Edition

Tabla 2 Límites de la luz visible según los colores RGB

Colores	LIMITES
Azul	0.4 - 0.5 μm
Verde	0.5 - 0.6 μm
Rojo	0.6 - 0.7 μm

Fuente: Introduction to Remote Sensing Fift Edition

1.5.1.10. Extracción de características

Hay diferentes modelos de pantalla o color. Los cuales se clasifican en dos categorías. Algunos pueden ser sensoriales, mientras que los demás se llaman perceptuales. La idea primordial de Get Features by Color es leer los datos más resaltantes en formato RGB de un objeto para crear datos

representativos que se pueden usar en otros procesos para obtener resultados.[25].

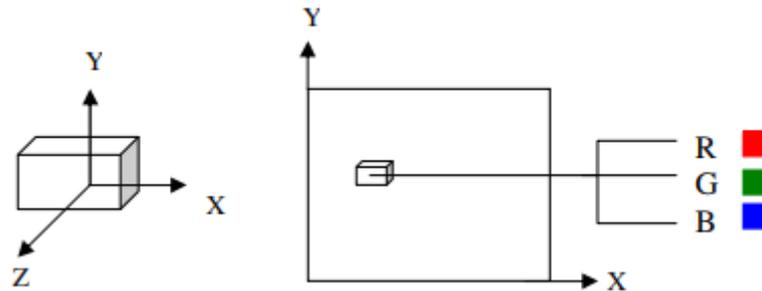


Fig. 9 Obtención de características del objeto por color [25]

Modelo sensorial. El modelo RGB básico viene utilizando colores primarios normalizados de rojo, verde y azul. La cámara y el receptor se basan en este modelo. Sin embargo, al usarlo para el procesamiento de imágenes (alineación), surge un problema) [25].

Modelo perceptual. Modelo HSI (Hue, Saturation, Intensity) Esto tiende visualizarse en modo transición del espacio RGB al espacio perceptivo. En inicios, los modelos de percepción deberían aumentar a medida que hacemos pruebas utilizando recursos para mejora [25].

Etiquetamiento. Al buscar un objeto por color, se busca su umbral y cuando se encuentra, se cambia al valor definido. De esta manera, aparecen valores definidos uniformes en la imagen [25].

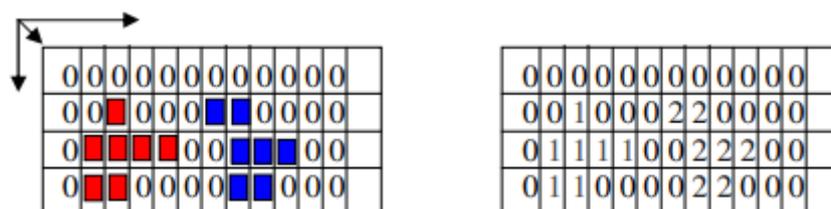


Fig. 10 Etiquetamiento [25]

Modelos de color. Su propósito de este modelo (también conocido como espacio o sistema de color) da facilidad a la especificación de colores de una manera estándar o generalmente aceptada. Este tipo de modelo nos especifica que es un sistema de coordenadas y sus subespacios, en el cual cada color puede simbolizar por un solo punto [20].

modelo HIS. Esto se conoce como modelo de color de matiz, saturación e intensidad (HSI) y separa los componentes de intensidad de información de color en las imágenes en color. Por lo tanto, el modelo se convierte en herramienta primordial para desarrollar algoritmos basados en las descripciones intuitivas y naturales del color que hacen las personas. En última instancia, el modelo RGB es adecuado para generar imágenes en color, pero su aplicabilidad para la descripción del color es limitada [20].

Conversión de RGB a HSI. Tal fórmula puede derivarse del razonamiento geométrico que acabamos de ver. El componente de tono H viene dado por:

$$H = \begin{cases} \theta \\ 360 - \theta \end{cases}$$

Donde

$$\theta \cos^{-1} = \frac{\frac{1}{2} [(R - G)] + (R - B)}{[(R - G)^2 + (R - B)(G - B)]^{\frac{1}{2}}}$$

$$Si B \leq G$$

$$Si B > G$$

El componente S de saturación:

$$S = 1 - (3/(R + G + B))[\min (R, G, B)]$$

Y el de intensidad:

$$I = (R + G + B)/3$$

Suponiendo sus valores RGB que son normalizados dentro del rango [0, 1] y el ángulo R se mide desde el eje rojo del espacio HSI. Un tono se puede normalizar al rango [0, 1] dividiéndolo por 360. La entrada de valores RGB están normalizados, los demás componentes están normalizados [20].

1.5.1.11. Support Vector Machine (SVM)

SVM es una solución a problemas difíciles de clasificación binaria y ahora se utiliza para resolver otros tipos de problemas (regresión, agrupamiento, clasificación múltiple).

En las tareas de clasificación, las SVM caen en la categoría de clasificadores lineales porque introducen separaciones lineales o hiperplanares en el espacio de instancia de entrada original si estas separaciones son separables o semiseparables. (ruido)[26].

Generalidades de las SVM

La construcción de Support Vector Machines (SVM) su base de representación es modificar o bosquejar un conjunto de datos concernientes a una dimensión dada n en un espacio dimensional sobresaliente utilizando una función kernel. SVM se usó originalmente en la resolución de problemas en clasificación y observación de patrones, luego se extendió al estudio para pronósticos de series de tiempo. La dificultad en la organización utiliza en alcanzar soluciones cualitativas, como para decidir clase en datos de ingreso o particularidad, entretanto los problemas tipo regresión vienen a

ser los más útiles en la obtención de resultados cuantitativos, logrando exitosamente salida numérica de los datos.[27].

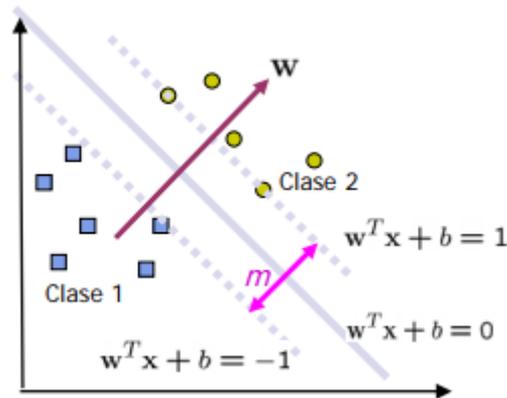


Fig. 11 Puntos de entrada [28]

El punto de entrada está en R^2 , por lo que SVM lo asigna a R^3 y hallar un hiperplano cuyo rango separa y maximiza el borde m entre clases en esta dimensión [28], ejemplo de muestra en la figura Fig 11.

SVM Clasificación Binaria Separables Linealmente

Dado un conjunto separable de ejemplos

$$S = \{(x_1, y_1), \dots, (x_n, y_n)\}$$

donde $x_i \in R^d$ e $y_i \in \{+1, -1\}$, podemos determinar el hiperplano de clasificación (ver Fig. 1a) en una función lineal capaz de dividir el conjunto dado sin error[26]:

$$D(x) = (w_1 x_1 + \dots + w_d x_d) + b = w \cdot x > +b$$

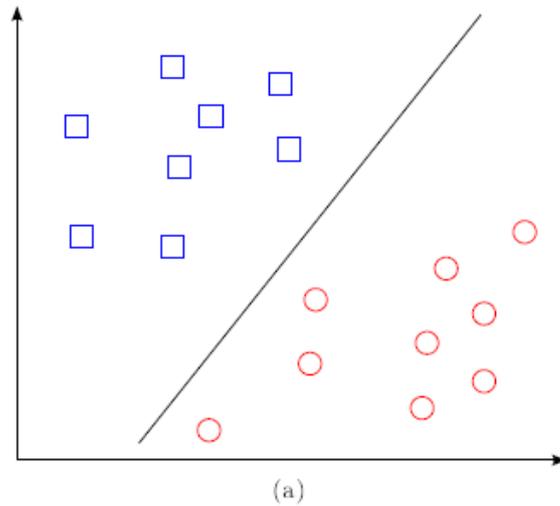


Fig. 12 Separación de hiperplanos en un espacio bidimensional a partir de un conjunto de ejemplos que se pueden separar en dos clases: (a) ejemplos de separación de hiperplanos [26]

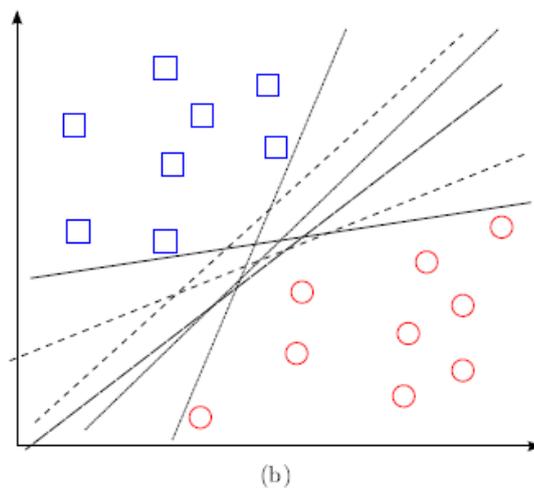


Fig. 13 Hiperplano de separación infinitos [26]

donde w y b son coeficientes reales. Para todos los " x_i " ejemplos juntos, el hiperplano de separación satisfará las próximas restricciones:

$$w, x_i > +b \geq 0 \text{ si } y_i = +1$$

$$w, x_i > +b \leq 0 \text{ si } y_i = -1$$

O también,

$$y_i(w, x_i > +b) \geq 0 \quad \text{ó} \quad y_i(D(x)) \geq 0$$

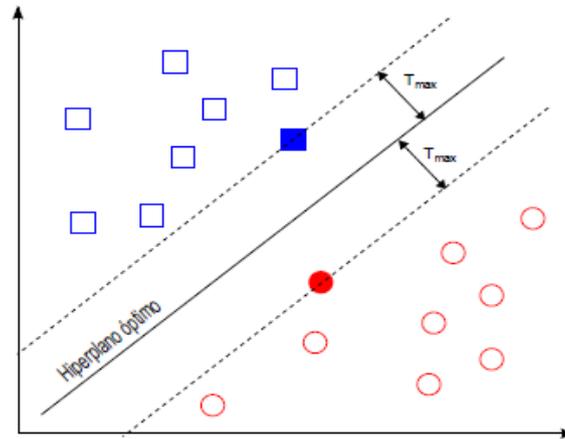


Fig. 14 Margen de un hiperplano de separación: hiperplano de separación óptimo y su margen asociado (máximo) [26]

SVM Clasificación Binaria Cuasi-Separables Linealmente

El hiperplano de separación se define con variables de holgura, ϵ_i $i=1, \dots, n$, que cuantifican ejemplos no separables, que estamos dispuestos a aceptar [26], es decir:

$$y_i(\langle w, x_i \rangle + b) \geq 1 - \epsilon_i, \quad \epsilon_i \geq 0, \quad i = 1 \dots n$$

Caso linealmente no separable

El dilema de aprendizaje de la sección anterior se aplica a estos casos linealmente dispersos, es decir, no hay corte en los datos de entrenamiento porque los puntos del corte no se pueden clasificar correctamente. existen sucesos de datos linealmente dispersos los cuales producen ruido debido a errores de medición en datos o algunos valores atípicos o extremo [27] (fig 15).

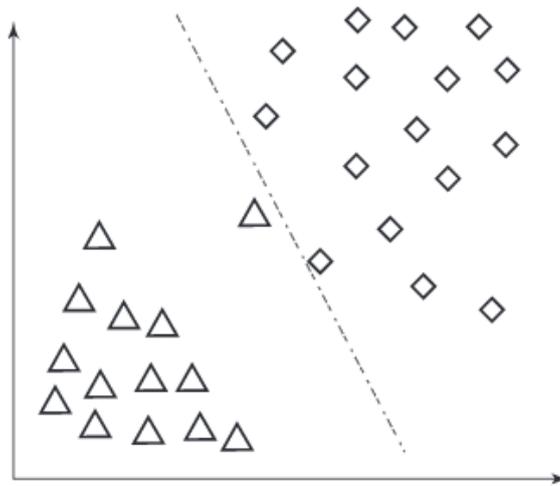


Fig. 15 Datos atípicos en el proceso de clasificación [27]

Estos pueden considerarse datos atípicos o mal clasificados. Esto no debe tenerse en cuenta al buscar límites de decisión, ya que puede cambiar el resultado deseado y dar lugar a una clasificación incorrecta.[27] (fig 16).

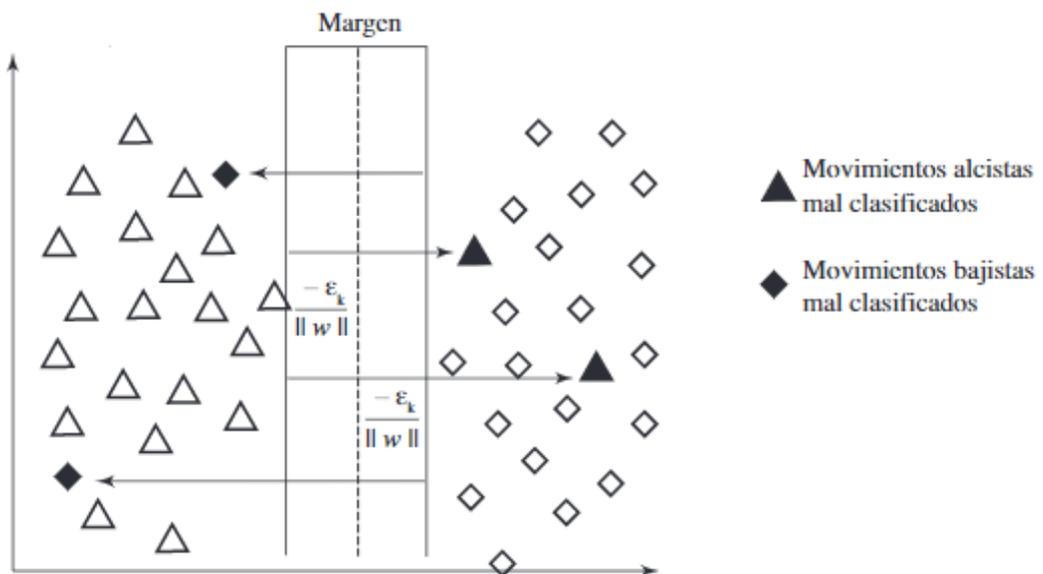


Fig. 16 Separación de dos clases – Datos linealmente no separables [27]

Los triángulos y rombos negros son submuestras que impiden su separación. Extender este método SVM al caso separable no lineal [27].

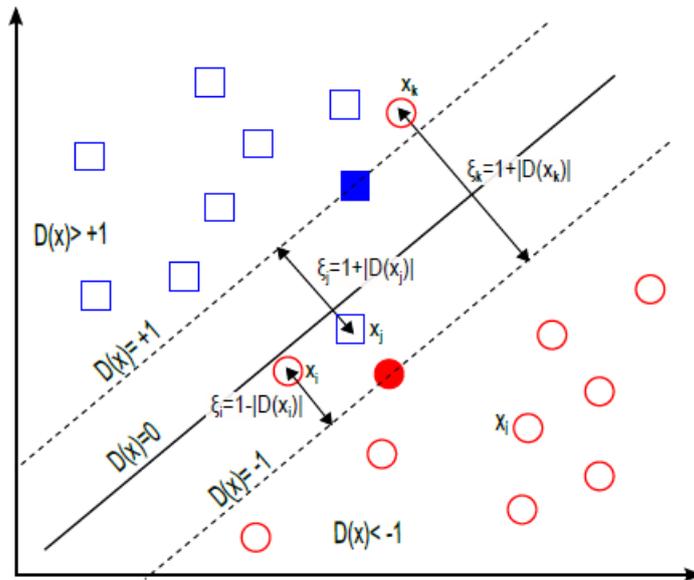


Fig. 17 Hiperplano no-separable [26]

La variable de holgura mide la desviación del borde marginal de la clase conveniente. Por tanto, todos los ejemplos x_i , x_j y x_k son inseparables $\epsilon_i, \epsilon_j, \epsilon_k > 0$. Sin embargo, x_i está clasificado perfectamente, mientras que x_j y x_k están en el lado equivocado del límite de decisión y, por lo tanto, están clasificados erróneamente [26].

SVM no lineales kernel machines

Estas no son funciones lineales y no pueden separar datos linealmente en su espacio de entrada; Se debe utilizar un método que permita generalizar el uso de SVM a tales problemas, [27].

$$x_k(x_k * w + b) - 1 \geq 0 \forall k$$

$$y_k(x_k * w + b) - 1 + \epsilon_k \geq 0 \text{ donde } \epsilon_k \geq 0 \forall k$$

Estos datos de entrada no son separables linealmente y es posible transformarlos en un espacio de singularidad de euclidiano de considerable magnitud. Los datos en el espacio de entrada y la nueva ubicación de

llegada que utiliza el algoritmo de aprendizaje para la función.[27], como se observa en la fig.18

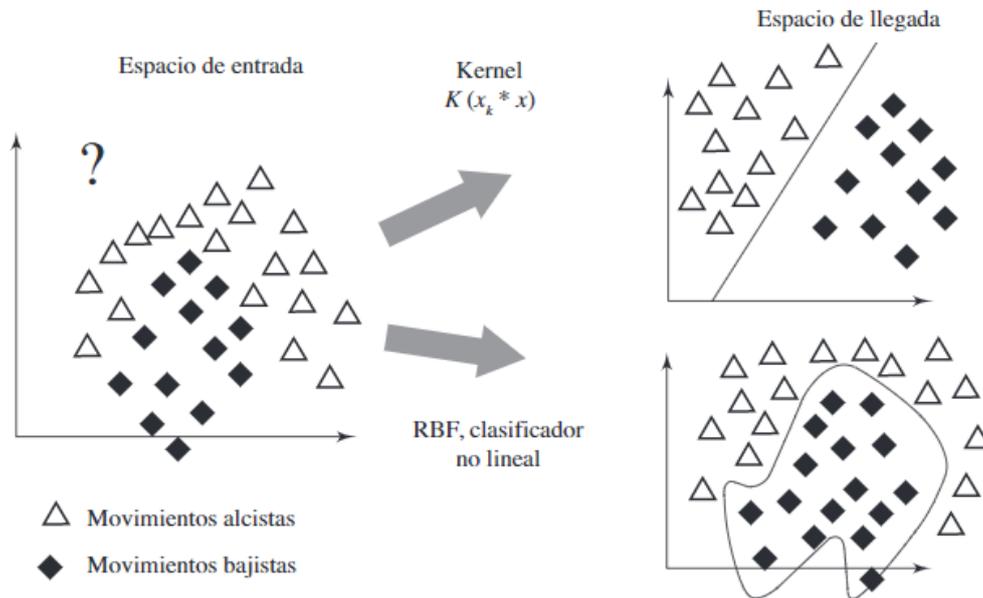


Fig. 18 Transformación de los datos a través del kernel [27]

Las funciones kernel repetidamente emplear por medio de SVM son:

Kernel lineal: Es recomendado utilizarlo en caso de vectores de datos dispersos [27].

$$K(x_i, x_j) = x_i * x_j$$

Kernel polinomial: Se utiliza ampliamente para modelar relaciones no lineales.

A medida que aumenta el parámetro d (grado polinómico), la superficie de clasificación tiende a volverse más compleja [27].

$$K(x_i, x_j) = (1 + x_i * x_j)^d$$

Kernel gaussiano: El más utilizado es el núcleo radial o núcleo gaussiano. El parámetro σ es el eje principal del hiperplano de separación, el éxito de la optimización depende del uso del método de validación cruzada [27].

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

Otras funciones kernel:

Neural (Sigmoid, Tanh) kernel:

$$K(x_i, x_j) = \tanh(ax_i * x_j + b)$$

Anova kernel:

$$k(x_i, x_j) = \left(\sum_i \exp(-y(x_i, x_j)) \right)$$

Fourier series kernel:

$$k(x_i, x_j) = \frac{\text{sen}(N + 1/2)(x_i, x_j)}{\text{sen}(1/2(x_i, x_j))}$$

Spline kernel:

$$k(x_i, x_j) = \left(\sum_{r=0}^k x_i^r x_j^r + \sum_{s=1}^N (x_i, t_s)^k + (x_j - t_s)^k \right)$$

Máquinas de soporte vectorial

El hiperplano está diseñado como una métrica de decisión para maximizar la separación entre clases positivas y negativas. El SVM aprende a diferenciar entre objetos con movimiento alcista y bajista asignando un vector $x \in R^d$ al conjunto de datos de entrenamiento y una clase $y_i \in \{1, 0\}$. El uso de un clasificador binario 1 y 0, función de decisión en los datos

proporcionados minimiza el riesgo de clasificar erróneamente datos futuros [27].

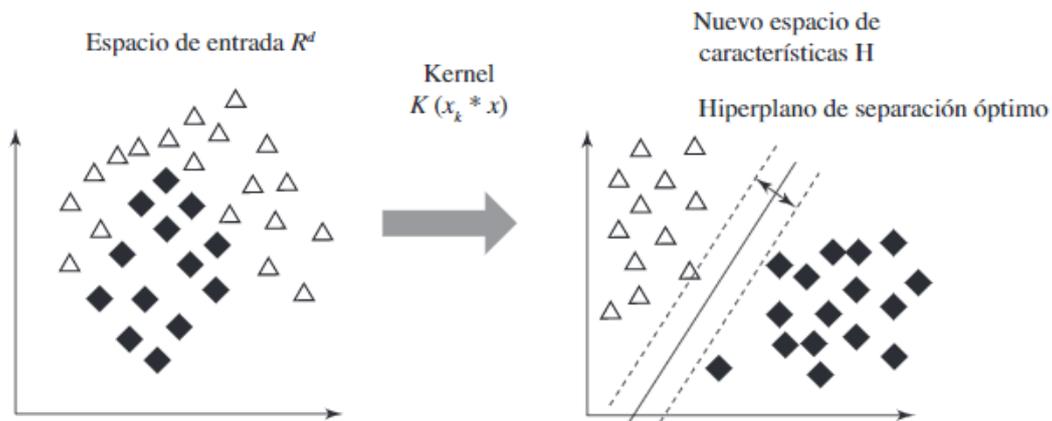


Fig. 19 Implementación de kernels [27]

Metodología de validación de los resultados

Ambos modelos utilizan medidas que cuantifican el desempeño esperado. Para hacer esto, considere el concepto de matriz de confusión, una herramienta de visualización utilizada en el aprendizaje supervisado, donde cada columna de la matriz representa el número de predicciones para cada clase y cada fila representa el número de instancias de cada clase. Una de las ventajas de las matrices de confusión es que facilitan determinar si un sistema está mezclando clases y proporcionan herramientas para seleccionar el mejor modelo posible y excluir los menos buenos [27].

		Valor real		Total
		P	N	
Valor predicción	P	Verdaderos positivos	Falsos positivos	P
	N	Falsos negativos	Verdaderos negativos	
Total		P	N	

Verdaderos positivos (VP)
Verdaderos negativos (VN)
Falsos positivos (FP)
Falsos negativos (FN)

Fig. 20 Matriz de confusión [27]

Los siguientes son los principales criterios de precisión para los experimentos de SVM:

$$\text{Precisión en la clasificación total} = \frac{VP+VN}{VP+FP+VN+FN}$$

$$\text{Precisión en la clasificación de verdaderos positivos} = \frac{VP}{VP+FP}$$

$$\text{Precisión en la clasificación de falsos negativos} = \frac{VN}{VN+FN}$$

1.5.1.12. Reflectancia espectral

Es la relación entre la potencia reflejada de un objeto y la energía suceso en una extensión de onda determinada. [7].

$$p_{\lambda} = \frac{ER(\lambda)}{EI(\lambda)}$$

Donde:

$$p_{\lambda} = \quad = \text{Reflectancia espectral}$$

$$ER(\lambda) = \text{Energía reflejada}$$

$$EI(\lambda) = \text{Energía incidente}$$

1.5.2 Definición de términos básicos

Procesamiento de imágenes

Conjunto de técnicas aplicadas a las imágenes digitales para mejorar su calidad o facilitar la búsqueda de información. Algunas definiciones facilitan la comprensión del procesamiento de imágenes.

Proceso de adquisición

La imagen digital se captura, se convierte, se digitaliza, se procesa y se almacena en un disco duro o tarjeta de memoria.

Preprocesamiento

Proceso de preparación de imágenes para su análisis, como: normalización, filtrado o ajuste.

Segmentación de la imagen

Se basa en dividir e separar la imagen en regiones homogéneas facilitando el análisis.

Descripción del objeto

Implica analizar y extraer características relevantes del objeto, como: color, textura y forma.

Pixel

El componente fundamental de una imagen digital mostrada en la pantalla. (picture element).

Imagen

Es una representación visual de escena o concepto, se compone de pixeles (unidades de color).

x
→

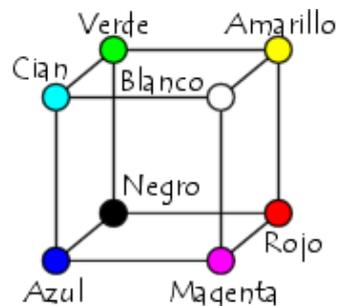
	0	1	1	2
	7	6	6	5
y	6	0	4	0
↓	5	5	1	2

Imagen de 16 pixeles

En cada pixel está representada por n bits, entonces existirán 2^n escala de gris diferentes. Matemáticamente, una imagen se representa por $r = f(x, y)$, donde r es la intensidad luminosa del pixel cuyas coordenadas son (x, y) .

Espacio RGB

Se basa en la combinación de tres señales de luminancia cromática distinta: rojo, verde, azul (Red, Green, Blue). Una forma en simplicidad de obtener un resultado específico es verificar la cantidad de rojo, verde y azul deben de mezclarse para obtener el color deseado, para lo cual se realiza la suma aritmética de los componentes: $X = R + G + B$, representado gráficamente por un cubo.



Color

Una mezcla de tres colores específicos: rojo, azul y verde (RGB en inglés). A continuación, se presentan algunas definiciones básicas para comprender los espacios de color:

Brillo

Todo indica si un área está regularmente iluminada.

Tono

Cabe Indicar parcial o total de un área pareciera ser similar al cualquiera de estos colores rojo, amarillo, verde o azul.

Luminosidad

Diferenciación de iluminación en una zona con respecto a otra en la imagen.

Algoritmo

Conjunto de instrucciones definidas, reglas bien definidas, ordenadas y acotadas permitiendo realizar una determinada acción en pasos sucesivos sin levantar sospechas de quien la realizará.

Espectro visible

Es el espectro de radiación electromagnética visible para el ojo humano. Su longitud de onda está entre 400 y 700 nm.

Longitud de onda

Tiene que ver con la frecuencia y energía de la luz que determina cómo percibimos el color.

Reflectancia espectral

El porcentaje va de 0 a 100 fracción entre 0 y 1 se utiliza para expresar la reflectancia de la muestra. Cabe señalar que los valores de reflectancia obtenidos son relativos no son relativos para muestras que no son fluorescentes. La cantidad de luz empleada para iluminar la muestra. A lo que se hace referencia es a la correlación entre la energía electromagnética entrante y la energía reflejada de la interfaz.

II. MATERIALES Y MÉTODO

2.1 Tipo y Diseño de Investigación

Básica y aplicada, se define:

Investigación básica: Esencialmente, realizar trabajos experimentales o teóricos para obtener nuevos conocimientos sobre los fenómenos y las bases de los hechos observables sin tener en cuenta su aplicación o aplicación particular.

Investigación aplicada: Existe un trabajo primitivo para adquirir nuevos conocimientos, pero principalmente con un propósito práctico específico.

2.1.1. Tipo de investigación

El presente trabajo es de tipo cuantitativo debido a la utilización de datos numéricos para poder realizar mediciones y comparaciones. De acuerdo [24] la investigación cuantitativa los datos son producto de mediciones y se representan por medio de cifras y se deben analizar con métodos estadísticos.

2.1.2 Diseño de investigación

Es cuasiexperimental ya que el presente trabajo de investigación será desarrollado por el autor mismo.

2.2 Variables, Operacionalización

Durante la operacionalización de variables, demostrar cómo convertir una variable conceptual en una práctica, utilizando indicadores que permitan cuantificar la variable:

2.2.1 Variable independiente

Máquinas en soporte de vectores

2.2.2 Variable dependiente

Detección automática de la enfermedad lasiodiplodia del palto.

2.2.3 Operacionalización de la variable

Variable del estudio	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Ítems	Instrumento	Valores finales	Tipo de variable	Escala de medición
Variable independiente	Máquinas de soporte de vectores	(Es un conjunto de procedimientos, técnicas y métodos para medir una variable directamente de la realidad, problema o fenómeno a investigar)	Eficiencia	Consumo de cpu. Consumo de ram.	Cm = consumo de ram Cc= consumo de cpu	Documentación	%	Numérica	$Cm = \sum_i^n \frac{cm_i}{n}$ $Cc = \sum_f^n \frac{cc_j}{n}$
Variable dependiente	Detección automática de la enfermedad lasiodiplodia del palto	Es la proporción de muestras correctamente diagnosticadas del total	Desempeño	Precisión	M=número de clases TP=valores adecuadamente marcados como positivos FP= valores erróneamente marcados como positivos	Se realizará usando técnica de observación	%	Numérica	$\frac{\left(\sum_{I=1}^M \frac{TP_i}{TP_i + FP_i}\right)}{M}$

				Sensibilidad	M=número de clases TP=valores adecuadamente marcados como positivos FN=valores marcados erróneamente como negativos	Se realizará usando técnica de observación	%	Numérica	$\frac{\left(\sum_{I=1}^M \frac{TP_i}{TP_i + FN_i}\right)}{M}$
		Porcentaje de área de tejidos cubiertas con síntomas	Inflexible	Severidad	P(i,j)=pixel de la enfermedad T(i,j)=número total de pixeles segmentada	Se realizará usando técnica de observación	%	Numérica	$\frac{\sum_{i,j} p(i,j)}{T(i,j)} \times 100$

2.3 Población de estudio, muestra, muestreo y criterios de selección

2.3.1 Población

Muestra enfermedades de las ramas en las imágenes que fueron tomadas en total son 150, que pueden ser detectadas como enfermas reales y enfermas falsas (Anexo1).

2.3.2 Muestra

La muestra de estudio aproximada con que trabajaremos es de 54 imágenes digitales de las ramas buenas y 96 con la presencia de la enfermedad lasiodiplodia capturadas en un ambiente no controlado.

2.4 Técnicas e instrumentos de recolección de datos, validez y confiabilidad

2.4.1 Técnicas de recolección de datos

Se usará las siguientes técnicas:

a) Observación

Es un registro visual de lo sucedido en una situación real según el esquema previsto, y los hechos relacionados se clasifican y registran según la pregunta de investigación.

2.4.2 Instrumentos de recolección de datos

b) Ficha de observación

Las fichas de observación se consideran un procedimiento de investigación cuyo contenido básico es la capacidad de utilizar herramientas adecuadas para establecer relaciones entre hipótesis y hechos mediante la observación científica y la investigación sistemática y ordenada. Las hojas de observación son herramientas que se utilizan para registrar descripciones detalladas de lo que se observa y de lo que se estudia, y se cree que también

permiten la recopilación de datos basada en objetivos cuando se identifican variables específicas.

2.5 Procedimiento de análisis de datos

Con base en la técnica de recolección de datos, profundizaré en las consideraciones:

- A. En la primera fase se tomarán las imágenes obtenidas de la cámara canon.
- B. En la segunda fase se prepara la base de datos con imágenes obtenidos de la cámara.
- C. En la tercera fase se someten las imágenes digitales de los tallos sanos y enfermos.
- D. En la cuarta fase se implementará las técnicas de detección en imágenes digitales.
- E. En la quinta parte se evaluarán los resultados.

Para evaluar cada técnica y descripción de la forma utilizada en cada prueba, se calcula la siguiente forma matemática:

a) Precisión

es la proporción de muestras correctamente diagnosticadas en la muestra total.

$$\frac{\left(\sum_{i=1}^M \frac{TP_i}{TP_i + FP_i}\right)}{M}$$

b) Sensibilidad

Tenga en cuenta cuánta luz se necesita para capturar la imagen; la cantidad de píxeles distribuidos aleatoriamente aumentará.

$$\frac{\left(\sum_{i=1}^M \frac{Tp_i}{TP_i + FN_i}\right)}{M}$$

c) Severidad

Porcentaje de área de tejidos cubiertas con síntomas.

$$\frac{\Sigma_{i,j}p(i,j)}{T(i,j)} \times 100$$

2.6 Criterios éticos

Derechos de autor: En todos los materiales utilizados en el proceso del tema de tesis se citará a los respectivos autores y se citará como colaboradores del trabajo.

Confidencialidad: Garantizar la protección de las fuentes y la identidad de los involucrados en la investigación como informantes.

III. RESULTADOS Y DISCUSIÓN

3.1 Resultados

Para evaluar el método propuesto, las muestras se dividieron en entrenamiento y pruebas de conjunto de datos. El conjunto de entrenamiento se usa para entrenar el clasificador SVM, mientras que el conjunto de prueba se usa para predecir la precisión del clasificador. obtienes lo siguiente:

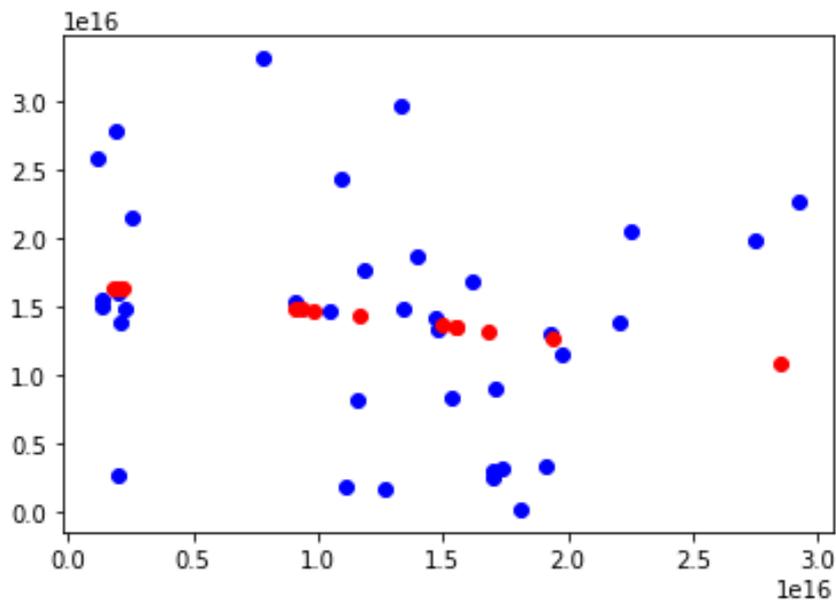


Fig. 21 Clasificación de clases SVM

La Fig 21 usando SVM. Este es un método para diferenciar las clases u objetos en la imagen. En este proceso, el SVM diferencian la imagen de la muestra en 2 clases con respecto al píxel de color de cada imagen utilizando un espacio n dimensión.

En la fig 22 muestra la característica de dos clases tallo bueno y tallo malo, se observa que el tallo bueno tiene menor intensidad de color y en el tallo malo es mayor la intensidad de color, por la presencia de lasiodiplodia.

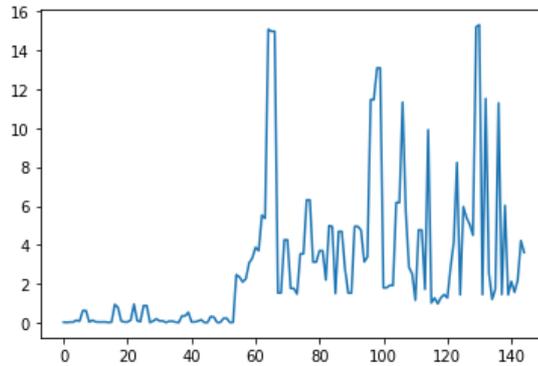


Fig. 22 Intensidad características de color

	precision	recall	f1-score	support
bueno	1.00	0.92	0.96	12
malo	0.95	1.00	0.97	18
accuracy			0.97	30
macro avg	0.97	0.96	0.96	30
weighted avg	0.97	0.97	0.97	30

Fig. 23 Resultados clasificación del SVM

En la Fig 23 la precisión del clasificador SVM para la enfermedad lasiodiplodia las imágenes de pruebas utilizado en la clasificación a someterse la muestra ensayada se obtuvieron con una precisión de 100% , en la sensibilidad describe un porcentaje de clasificaciones exitosas de cada clase, en 'f1-score' se puede interpretar entre la precisión y la sensibilidad, el 'support' describe el total de datos de cada clase tomadas del dataset, el 'micro' es la suma de verdaderos positivos, falsos negativos y falsos positivos, "macro" calcula la métrica de cada etiqueta y encuentra su promedio no ponderado, y finalmente "ponderado" encuentra el peso promedio de cada soporte, es decir. recuento real de casos para cada etiqueta, clasificación 97% exitosa de ramas enfermas y sanas.

Para el resultado del clasificador SVM se dividen datos de entrenamiento y pruebas, enviando al algoritmo de aprendizaje un 20% de pruebas para clasificar las ramas malas y buenas. Obteniendo el dataset con síntomas de lasiodiplodia en ramas mala una precisión de 95% y en buena un 100% asintomático.



Fig. 24 Precisión del clasificador SVM de pruebas

En la Fig 25 de la matriz de confusión en la clasificación total de numero de muestras son 30, en los verdaderos positivos(VP), falsos positivos(FP), falsos negativos(FN), verdaderos negativos(VN). Obteniendo como resultado una precisión de 96% total al clasificar.

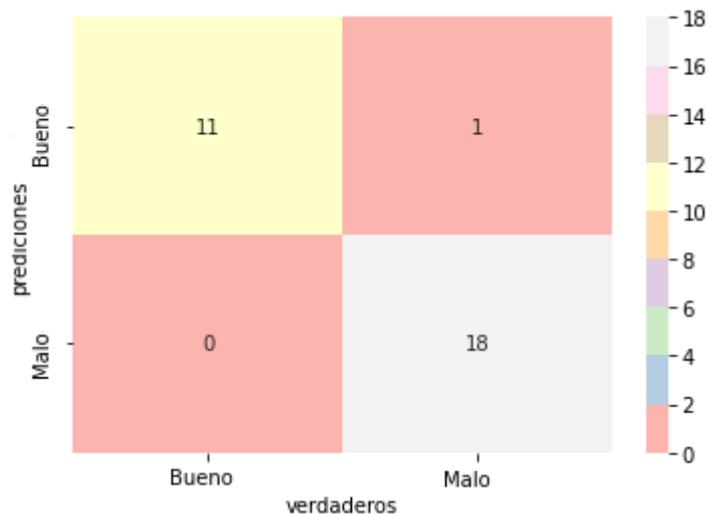


Fig. 25 Matriz de confusión de resultados

3.2 Aporte de la investigación (opcional)

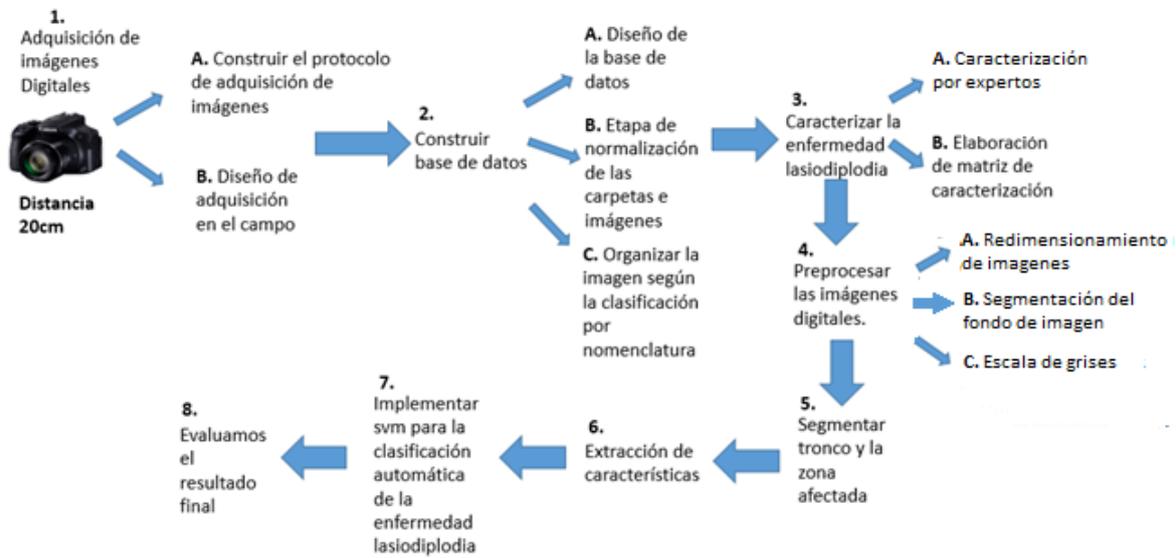


Fig. 26 Método Propuesto

1. Adquisición de imágenes digitales

A. Construir el protocolo de adquisición de imágenes

La adquisición de las imágenes fueron tomadas en la asociación de productores de palta Hass “Augusta López Arenas” en la provincia de Ferreñafe distrito de Pítipo, dichas coordenadas de -6.560002, -79.777984, estas imágenes digitales fueron tomadas con una cámara de marca canon semiprofesional de modelo SX50 HS de 12.1 MP(Mega-Pixeles) a una distancia de 20cm, medidos con una regla graduada de 30cm, las imágenes fueron capturadas con un enfoque automático sin zoom, sin flash, sin filtros en un ambiente no controlado con una apertura de la cámara automático entre el $f/3 - f/5$, la cantidad de luz que necesito la cámara para hacer las fotografías se calculó de manera automática con una oscilación entre el ISO 120-160



Fig. 27 Protocolo de Adquisición de Imágenes

Fuente: Elaboración Propia

B. Diseño de adquisición en el campo.

La adquisición de imágenes en el campo se realizó de la siguiente manera: se logró visualizar que los síntomas principalmente son manifestados en tallos, en los que se tomaron las imágenes sobre ellos, dividiendo esta adquisición en tallos sanos y tallos enfermos, y está a su vez se subdividieron en tallos sanos de dimensiones pequeñas, tallos malos de dimensiones pequeñas, tallos buenos de dimensiones grandes, tallos malos de dimensiones grandes, tallos con nudos sanos y tallos con nudos lastimados. considerándose como tallos con dimensiones pequeñas en los tallos secundarios que salían tallos principales cuyo grosor eran de 8 cm a 20 cm. Con respecto a los tallos con dimensiones grandes fueron considerados tallos principales con grosores de 20 cm a más. En cuanto a la posición de la cámara fue considerada de acuerdo a como La enfermedad se localiza en el tronco de tal forma que cubre toda la zona afectada por lo que las posiciones se consideran normales en posición horizontal, ángulo alto, ángulo bajo y cenital. así los tallos afectados longitudinalmente y

transversalmente. De esta manera se realizó la adquisición de imágenes, las cuales fueron guardadas en la micro SD sandisk, para posteriormente agregarlas a la base de datos.

2. Construcción de base de datos

A. Diseño de la base de datos

Para este propósito del diseño de la base de datos, las fases de entrenamiento y clasificación del sistema utilizan el repositorio de imágenes. El número total de imágenes utilizadas en este estudio de investigación es de 150. Las muestras extraídas se dividen en muestras defectuosas y muestras no defectuosas.

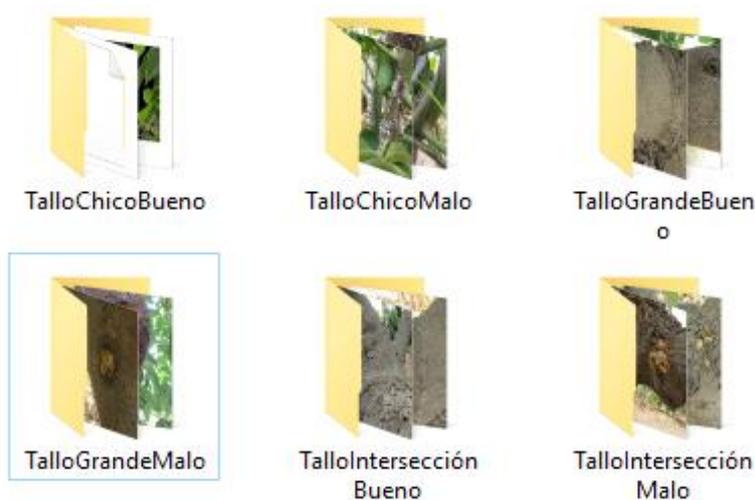


Fig. 28 Repositorio de imágenes digitales

Fuente: Elaboración Propia

B. Etapa de normalización de carpetas e imágenes

Este paso de nuestra investigación en la tarjeta de memoria SD sandisk que contiene las imágenes digitales se pasó al computador para construir la base de datos, se creó nuevas carpetas y se les nombró Tallos Buenos y Tallos Malos.

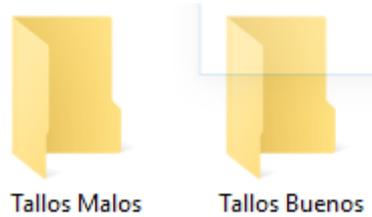


Fig. 29 Normalización de carpetas

Fuente: Elaboración Propia

C. Organizar la imagen según la clasificación por nomenclatura

Para este paso de nuestra investigación las carpetas se dividen en sub carpetas Tallo chico, Tallo grande y Tallo Intersección, del mismo modo las imágenes fueron nombradas de manera similar como: TChBXX.jpg Tallos pequeños demasiado buenos, TChMXX.jpg En tallos pequeños malos, en tallos grandes buenos, TGBXX.jpg, en tallos grandes malos, TGMXX.jpg, en tallos cruzados buenos, TIBXX.jpg, en tallos cruzados TIMXX.jpg malos del tallo.

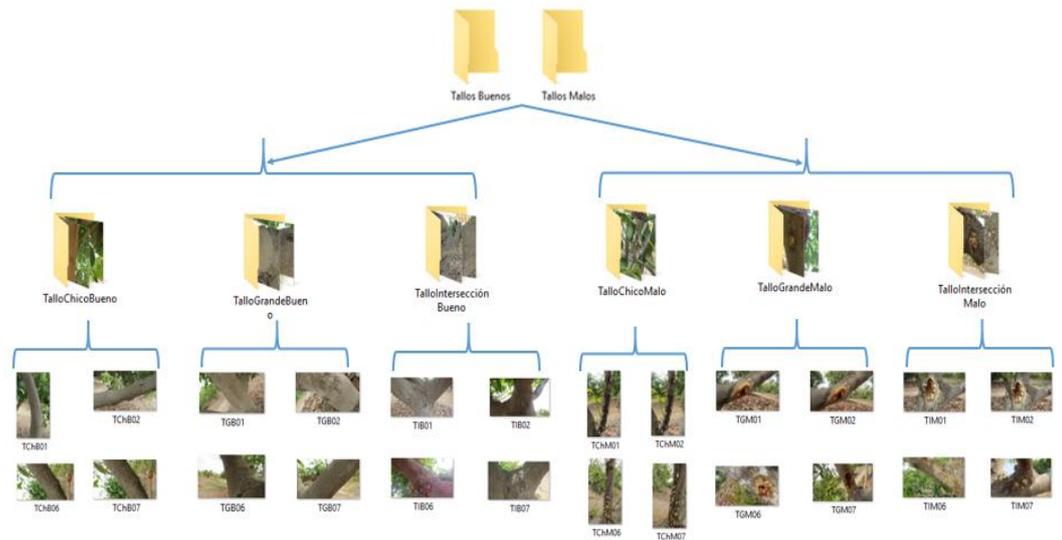


Fig. 30 Imágenes según la Clasificación por nomenclatura

Fuente: Elaboración Propia

3. Caracterización de la enfermedad lasiodiplodia

A. Caracterización por expertos

Explica que la enfermedad sucede cuando las plantas experimentan estrés hídrico. La lasiodiplodia es un hongo que eventualmente puede permanecer en el tejido sin que la planta muestre síntomas. Esto ocurre cuando el tejido se debilita por el estrés hídrico. Las esporas elementales se forman en las ramas muertas, mostrando un color marrón oscuro a negro. Los signos que presenta cuando las ramas afectadas son sometidas a condiciones de alta humedad relativa de 95-100% se forma un moho gris [3].

Explicó que el síntoma más común de la marchitez por lasiodiplodia es la aparición de canchales con exudados blancos y grumosos de varios tamaños que se distribuyen indistintamente a lo largo de los troncos de los árboles y ramas jóvenes y maduros infectados. Se observaron daños en tallos y ramas, provocando la muerte gradual de los brotes infectados. [19].

B. Elaboración de matriz de caracterización

Para este objetivo que es caracterización de la enfermedad lasiodiplodia según la escala de parcela de nivel de severidad: Asintomática, Inicial, Bajo, Moderado y Severo tienen un grado de daño.

Tabla 3 Escala De Parcela Nivel De Severidad

Etapas	Nivel de severidad
Asintomática	0
Inicial	0,5 - 1
Bajo	1,5 - 2
Moderado	2,5 – 3
Severo	3,5 - 4

Fuente: Elaboración Propia

Tabla 4 Etapa de caracterización de lasiodiplodia

Imagen	Estado	Descripción	Observación
	Etapa Asintomática	Tallo leñoso de color gris	sana
	Etapa Inicial	Pequeña área de chancro que abarca un color amarillo e amarillo pálido	Enfermo
	Etapa Bajo	Cancro ubicado a lo largo del tallo amarillo palido	Enfermo
	Etapa Moderado	Cancrosis de color marrón oscuro con secreciones blanquecinas como sal.	Enfermo
	Etapa severo	Necrosis de color marrón oscuro a necro que representa la muerte regresiva.	Enfermo

Fuente: Elaboración Propia

4. Preprocesar las imágenes

a) Redimensionamiento de imágenes

Para poder realizar las pruebas experimentales, se procedió a redimensionar las imágenes y estandarizarlas según la posición en que

fueron tomadas. El primer grupo es de imágenes tomadas en posición horizontal con una resolución de 450 píxeles de ancho y el segundo de 252 píxeles de largo (Anexo5). El segundo grupo está conformado de imágenes tomadas en posición vertical con una resolución de 252 píxeles de ancho y el segundo de 450 píxeles de largo, se consideró para ambos casos la misma resolución debido a que al momento de redimensionar las imágenes tomadas en posición vertical, automáticamente se pasaban al modo horizontal. Cada conjunto está formado por el mismo número de regiones infectadas y sanas.



Fig. 31 Imágenes redimensionadas 252 píxeles x 450

b) Segmentación del fondo de imagen.

Para iniciar el preprocesamiento de la imagen, es conveniente eliminar partes de la imagen que no sean necesarias para el procesamiento, de modo que se elimine el fondo de la imagen, dejando solo el área de interés para el estudio. Dicho proceso utiliza el algoritmo grabcut (Anexo6). Esto nos permite extraer automáticamente áreas de primer plano.



Fig. 32 Segmentación del fondo de la imagen

La fórmula de grabcut es la siguiente:

- a) Asigna fondo del primer plano GMM

$$a_n = 0 \text{ and } a_n = 1 \text{ respectively}$$

- b) Asigna componentes GMM pixeles

$$k_n := \arg \min_{k_n} D_n(a_n, k_n, \theta, z_n)$$

- c) Aprender parámetros GMM de datos Z

$$\underline{\theta} := \arg \min_{\underline{\theta}} U(a, k, \theta, z)$$

- d) Estimar la segmentación: utilizar corte min para resolver:

$$\min_{\{a_n : n \in Tu\}} \min_k E(a, k, \theta, z).$$

c) Escala de grises

Para encontrar el espacio de color más adecuado, se elige principalmente el espacio de color rgb2grey. Este espacio pretende proporcionar un espacio perceptualmente uniforme entre dos intensidades de color, donde cada celda de la matriz de la imagen en escala de grises está representada por 1 píxel. Esto corresponde a 1 byte, lo que permite 256 niveles de gris. de 0 (negro) a 255 (blanco) (Anexo7).

A pesar de que el espacio de color RGB es demasiado sensible a cambios en la iluminación, y los histogramas pueden variar mucho de una imagen a otra, según (Finlayson, Schiele, & Crowley, 1998) este efecto se puede reducir normalizando la imagen, de tal manera que se alcancen mejores resultados al momento de discriminar entre la región sana de la infectada. Por lo tanto, antes de comparar histogramas de dos regiones, los normalizamos, una técnica que implica expandir los valores de intensidad de píxeles de cada canal para cubrir todo el rango de valores de píxeles.

5. Segmentación

a. Segmentación otsu

El objetivo de la segmentación es reducir la representación de una imagen a otra que sea más significativa y más fácil de analizar, resaltando las características relevantes cuando sea necesario. Para esta fase de investigación se precedió a utilizar el algoritmo otsu para las imágenes separando el fondo quedándonos con el tronco que es nuestra región de interés, la notación matemática del algoritmo, luego el código fuente del algoritmo otsu que se está implementando en Python

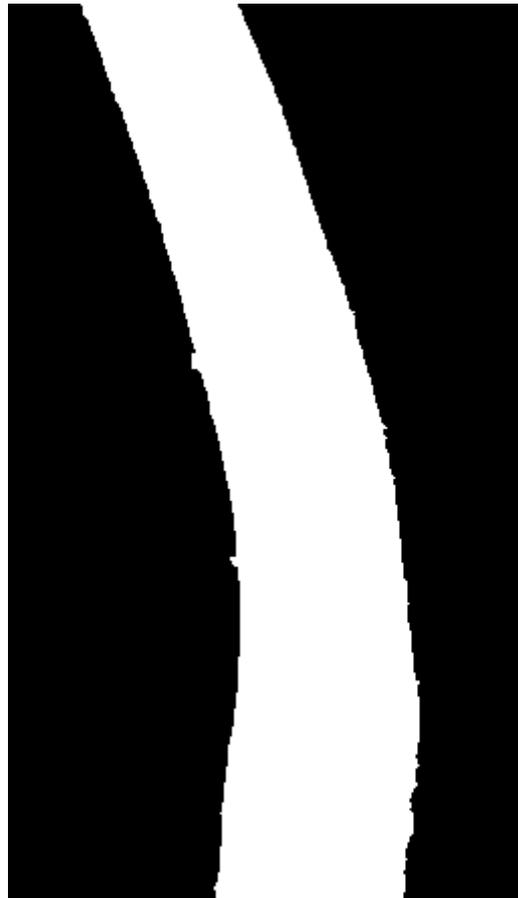


Fig. 33 Imagen binarizada

Umbral óptimo:

$$T = \max(\sigma^2)$$

Donde:

a) **Varianza:**

$$\theta^2 = w_B(\mu_B - \mu) + w_F(\mu_F - \mu)^2$$

b) **Probabilidad Acumulada:**

$$w_k = \sum_{i=0}^k P_i$$

c) **Media Acumulada:**

$$\mu_k = \sum_{i=0}^k i \cdot P_i$$

d) **Probabilidad Acumulada:**

$$\mu_c = \frac{\mu_k}{w_k}$$

B: Corresponde al fondo de la imagen ("Background")

F: Corresponde al objeto de la imagen ("Foreground")

b. Segmentación histograma

En la segmentación de histograma en hsv se convierte la imagen RGB normalizado en el espacio hsv. El espacio de color hsv se ha utilizado principalmente para la segmentación de la enfermedad del palto debido a razones siguientes: la imagen original se convierte a cielab, haciendo una conversión de color, se separa el canal 'b' de la imagen BGR a hsv obteniendo los valores max y min en hsv la zona infectada puede ser fácilmente detectado, la diferencia de color de la discriminación humano puede ser pronunciada directamente por distancia en el espacio de color hsv, la intensidad y componentes cromáticos se pueden utilizar por

separado y los puntos del tallo infectado forman agrupaciones en el espacio hsv.

En esta investigación de segmentación en histograma lo que se procedió es convertir a espacio de color cielab en la fig 34. La muestra del resultado donde se puede observar el color 'b' del espacio de color gr en la fig 35. Pasando así al espacio de color hsv (matriz, saturación, valor) obteniendo los valores mínimos y máximos. En la fig 36 se muestra el resultado del hsv. Estos valores del hsv que define el rango del color de la imagen en la fig 37. y finalmente se obtiene como resultado los niveles de bits y la máscara de la imagen original en la fig 38 convirtiendo a espacio de color RGB

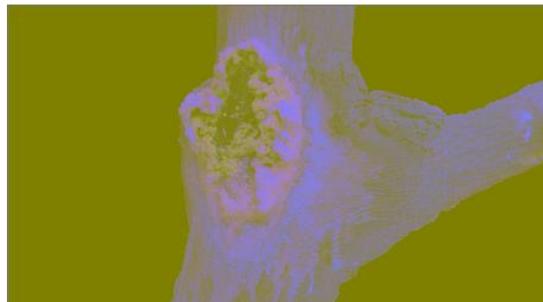


Fig. 34 Imagen de espacio de color cielab

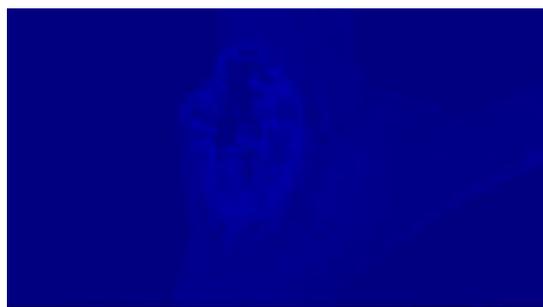


Fig. 35 Canal azul de la imagen

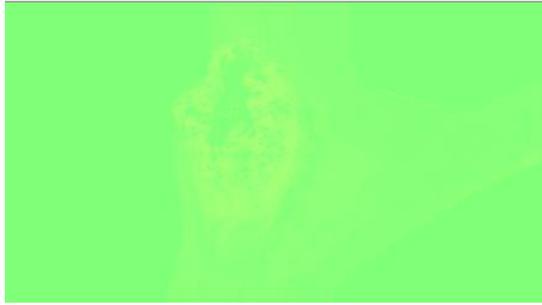


Fig. 36 Imagen de espacio de color hsv

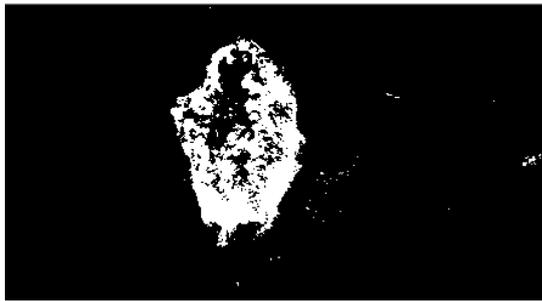


Fig. 37 Binarizacion de la imagen



Fig. 38 Imagen original del espacio de color RGB

El paso del espacio RGB al HSV viene dado por las siguientes ecuaciones:

$$H = \begin{cases} \arccos \frac{(R - G) + (R - B)}{2\sqrt{(R - G)^2 + (R - B)(G - B)}}, B \leq G \\ 2\pi - \arccos \frac{(R - G) + (R - B)}{2\sqrt{(R - G)^2 + (R - B)(G - B)}}, B > G \end{cases}$$

$$S = \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B)}$$

$$V = \frac{\max(R, G, B)}{255}$$

6. Extracción de características

En extracción de características el descriptor de color ha sido ampliamente utilizado para la imagen de recuperación ya que es muy estable y robusto. el histograma en hsv definir probabilidad de intensidad de los tres canales de color. La extracción de características de color parcial enferma se extraen los canales R de la imagen segmentada. el color como media y la desviación estándar en tres planos R, G, B se calculan. Obteniendo el total de características de la media del color.

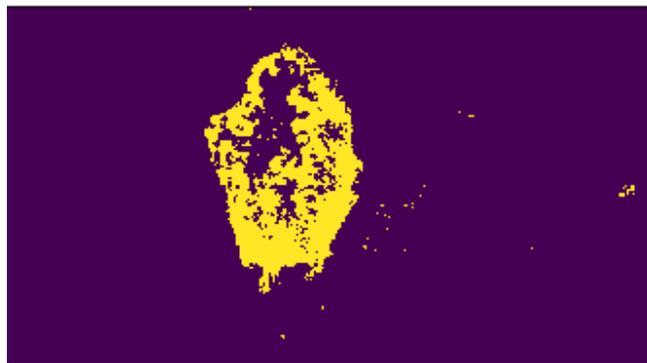


Fig. 39 Imagen de característica de color

En la fig 40 muestra el vector de característica esto se puede hacer mediante el uso de histograma RGB. Esta técnica, el color de la imagen se consideran para salir con las características que representa la imagen.

0.0286499	5.52101
0.00688406	14.9885
0.0286499	3.06676
0.0323478	2.19597
0.00800628	1.92098
0.0255015	6.18075
0.351561	1.77418
0.0805076	4.25578
0.0313885	1.75838
0.580599	5.36438
0.0366718	3.53639
0.0221876	3.11652
0.0641908	3.69506
0.0956218	6.30932

Fig. 40 Imagen de característica de color

7. Implementación de SVM

Para este objetivo de implementación de Support Vector Machines (SVM) el algoritmo de aprendizaje supervisado se utiliza como una herramienta de clasificación. SVM maximiza el margen entre los datos de entrenamiento y límite de la clase, transformando los datos de espacio de entrada en un espacio de alta dimensión de característica dando al vector como entrada al clasificador. Los vectores de características de las imágenes de base de datos se dividen en entrenamiento y prueba. El rendimiento del clasificador se mide comparando las etiquetas predichas y los valores reales.

En la clasificación del SVM se utilizó para clasificar la enfermedad del palto, separando el límite de la clase sana y enferma. Los algoritmos implementados en el clasificador de imágenes del palto al momento de entrenar dos clases se

pueden generalizar la clasificación del objeto por la característica de color para reconocer el estado de descomposición del tallo por su color.

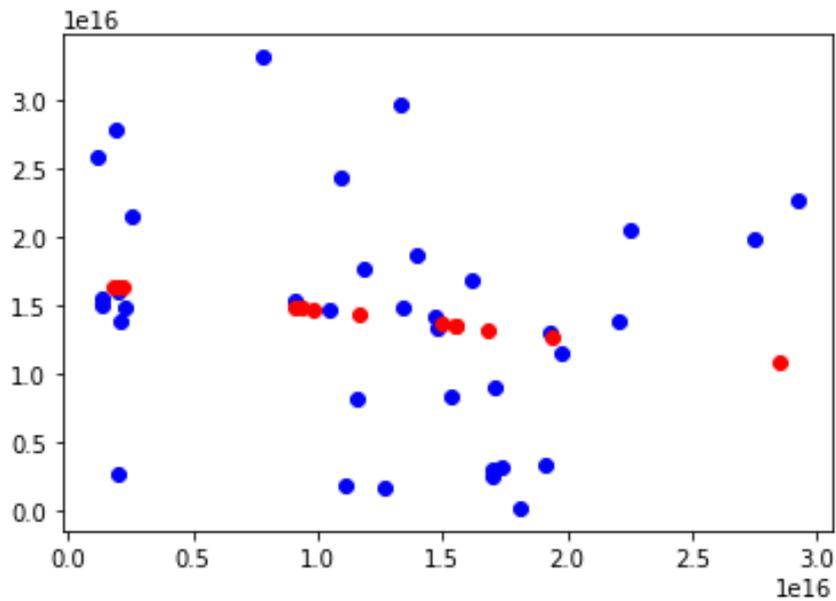


Fig. 41 Imagen de clasificación multiclase SVM

Para poder clasificar las dos clases de tallos buenos y sanos se realizó la extracción de características de color. En la fig 42 se muestran las características de color de tallos buenos y tallos malos

0.0286499	5.52101
0.00688406	14.9885
0.0286499	3.06676
0.0323478	2.19597
0.00800628	1.92098
0.0255015	6.18075
0.351561	1.77418
0.0805076	4.25578
0.0313885	1.75838
0.580599	5.36438
0.0366718	3.53639
0.0221876	3.11652
0.0641908	3.69506
0.0956218	6.30932

Fig. 42 Imagen de característica de color

8. Resultado final

Se obtiene como resultado la clasificación de las clases del tallo buenos y tallo enfermo con el 20% de pruebas al clasificar la enfermedad de lasiodiplodia mostrando con una precisión de 100% en los tallos buenos y 95% en los tallos malos. En la fig 43 se muestra la clasificación de precisión del clasificador SVM



Fig. 43 Precisión del clasificador SVM de pruebas

V. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

- a. Se logró obtener un gran repositorio con excelentes imágenes en las cuales se pudieron estudiar para determinar lo positivo y negativo que podemos encontrar y en este caso más centrado en la enfermedad lasiodiplodia.
- b. Para caracterizar a la enfermedad lasiodiplodia se consultó a expertos, y se elabora la matriz de caracterización según la escala de parcela de nivel de severidad: asintomática, inicial, bajo, moderado y severo.
- c. Se procesaron las imágenes obtenidas y como función se obtiene que se pudo detectar la enfermedad lasiodiplodia en los tallos en las cuales a partir de este estudio se puede tratar de difundir e informar para que los agricultores puedan tratar esta enfermedad en sus cultivos.
- d. La técnica de máquinas de soporte de vectores se clasifico los tallos buenos y tallos malos para detectar la presencia de la enfermedad de lasiodiplodia
- e. Los resultados de clasificación del SVM obtuvo un 100% en los tallos bueno y 100% en los tallos malos demostrando que es más preciso al detectar la presencia de lasiodiplodia

4.2 Recomendaciones

Gracias a la parte tecnológica en sistemas se ha permitido con precisión determinar y detectar las diferentes características que trae esta enfermedad en la agricultura de palto has

REFERENCIAS

- [1] M. Santos, "Presentación Estudio de palta en el Perú y el mundo," pp. 1–23, 2008.
- [2] Ministerio Agricultura y Riego Peru, "Tendencias de la producción y el comercio de Palta en el mercado internacional y Nacional," *Minagri*, p. 81, 2015.
- [3] M. F. Faizi, "MANEJO INTEGRADO DE ENFERMEDADES EN PALTO," vol. III, pp. 224–234, 2018.
- [4] H. Li, W. S. Lee, and K. Wang, "Spectral mixture analysis based citrus greening disease detection using satellite image of Florida," *Proc. 5th Work. Hyperspectral Image Signal Process. Evol. Remote Sens.*, pp. 3–6, 2013.
- [5] P. S. R, "Enfermedades que atacan a la alcachofa," pp. 111–122.
- [6] G. R. Vidango-Ponce, *Implementación de un sistema de procesamiento digital de imágenes para la detección de malezas en el cultivo de quinua*. Universidad Nacional del Altiplano, 2017.
- [7] DAYANA CECILIA OCAMPO ZEGARRA, *EFFECTO DE DAÑOS MECANICOS EN POST COSECHA Y CONTENIDO DE MATERIA SECA EN LA CALIDAD DE POST COSECHA DE FRUTOS DE PALTA (Persea americana Mill.) cv. HASS DE EXPORTACION. 2012. 2014.*
- [8] PUCE, "Pontificia Universidad Católica del Ecuador," 2018.
- [9] U. R. Palma and F. D. E. C. Biológicas, "“ Detección temprana del Potato Yellow Vein Virus en cultivos de Solanum tuberosum L . mediante la teledetección ’ Tesis para optar el Título Profesional de Licenciada en Biología," 2017.
- [10] E. D. Lucero Carrillo and H. A. Saldaña Saldaña, "Utilización de técnicas de visión artificial para la detección automática de defectos externos del mango," vol. I, p. 145, 2016.

- [11] H. Waghmare Student, R. Kokare Student, and Y. Dandawate Professor, *Detection and Classification of Diseases of Grape Plant Using Opposite Colour Local Binary Pattern Feature and Machine Learning for Automated Decision Support System.* .
- [12] A. Nor, I. Masazhar, M. Kamal, and U. T. Mara, "Digital Image Processing Technique for Palm Oil Leaf Disease Detection using Multiclass SVM Classifier," no. November, pp. 28–30, 2017.
- [13] G. K. Birajdar, "Computer Vision Based Approach to Detect Rice Leaf Diseases using Texture and Color Descriptors," no. Icici, pp. 1074–1078, 2017.
- [14] R. M. Prakash, "Detection of Leaf Diseases and Classification using Digital Image Processing," 2017.
- [15] Y. Dandawate and R. Kokare, "An automated approach for classification of plant diseases towards development of futuristic Decision Support System in Indian perspective," *2015 Int. Conf. Adv. Comput. Commun. Informatics, ICACCI 2015*, pp. 794–799, 2015.
- [16] S. C. Madiwalar and M. V Wyawahare, "Plant Disease Identification: A Comparative Study," pp. 13–18, 2017.
- [17] C. Joshi and S. Mukherjee, "Empirical analysis of SIFT, Gabor and fused feature classification using SVM for multispectral satellite image retrieval," *2017 4th Int. Conf. Image Inf. Process. ICIIP 2017*, vol. 2018-Janua, pp. 542–547, 2018.
- [18] G. León, "Control de plagas y enfermedades en los cultivos," pp. 242–243, 2007.
- [19] R. Wainschenker, "Procesamiento Digital de Imágenes Objetivos de la materia," 2011.
- [20] S. L. Potosí, "Procesamiento digital de imágenes," *Perfiles Educ.*, no. 72, 1996.
- [21] M. A. Castillo Martínez, F. J. Gallegos Funes, A. J. Rosales Silva, and R. I. Ramos Arredondo, "Preprocesamiento de imágenes dermatoscópicas para extracción de

- características Dermoscopic image preprocessing for feature extraction,” *Res. Comput. Sci.*, vol. 114, no. 2016, pp. 59–70, 2016.
- [22] M. L. G. G. DAMIÁN A. ÁLVAREZ G., “Preprocesamiento De Imágenes Aplicadas a Mamografías Digitales,” *Sci. Tech.*, vol. 12, no. 31, pp. 1–6, 2006.
- [23] P. Querejeta Simbeni and Estudiante, “Procesamiento digital de imágenes,” *Perfiles Educ.*, no. 72, pp. 1–5, 1996.
- [24] S. Ormeño-Villajos, “Teledeteccion fundamental,” p. 344, 2006.
- [25] Procesamiento de imagenes Iii, “Procesamiento de imágenes capítulo iii 33,” pp. 33–48, 2004.
- [26] E. J. Carmona Suárez, “Tutorial sobre Máquinas de Vectores Soporte (SVM),” p. 25, 2013.
- [27] N. Sánchez Anzola, “Máquinas de soporte vectorial y redes neuronales artificiales en la predicción del movimiento USD/COP spot intradiario,” *Odeon*, no. 9, p. 113, 2016.
- [28] G. Bentacourt, “Las Máquinas de Soporte Vectorial (SVMs),” *Sci. Tech.*, vol. 1, no. 27, pp. 67–72, 2005.
- [29] C. Pérez and Á. L. Muñoz, *Teledetección: nociones y aplicaciones*, vol. 53, no. 9. 2006.
- [30] S. Azuela, "procesamiento de imágenes digitales", 2006.

ANEXOS

Serán enumerados considerando:

- Instrumentos de recolección de datos.
- Consentimiento informado (Si la investigación se orienta a recopilar datos de personas).
- Carta de autorización para la recolección de la información.
- Evidencias de ejecución.

Otros que considere pertinente.

Anexo1: Población de la enfermedad

SVM	Total	Detectó	E. Reales	E. Falsas	Presión
Prueba N. 1					
Prueba N. 2					

La población de la enfermedad puede ser detectadas como enfermas reales y enfermas falsas

Anexo2: Lugar para recolectar las imágenes



La adquisición de las imágenes fue tomada en la asociación de productores de palta Hass “Augusta López Arenas” en la provincia de Ferreñafe distrito de Pítipo

Anexo3: Adquisición de imágenes



La adquisición de imágenes en el campo se logró visualizar que los síntomas principalmente se manifiestan que el cancro se ubica a lo largo del tallo, por lo que se tomaron imágenes sobre ellos.

Anexo4: Repositorio de imágenes digitales



Se utilizó un repositorio de imágenes para el entrenamiento del sistema como para la etapa de clasificación.

Anexo5: Código fuente redimensionamiento de imágenes

```
foo = Image.open("D:\Paltitas\TChB01.jpg")  
foo = foo.resize((450,252),Image.ANTIALIAS)  
foo.save("D:\Paltitas\TChB01.png",quality=95)
```

Anexo6: Código fuente del algoritmo grabcut

```
3 import numpy as np
4 import cv2 as cv
5
6 import sys
7
8 class App():
9     BLUE = [255,0,0]
10    RED = [0,0,255]
11    GREEN = [0,255,0]
12    BLACK = [0,0,0]
13    WHITE = [255,255,255]
14
15    DRAW_BG = {'color' : BLACK, 'val' : 0}
16    DRAW_FG = {'color' : WHITE, 'val' : 1}
17    DRAW_PR_FG = {'color' : GREEN, 'val' : 3}
18    DRAW_PR_BG = {'color' : RED, 'val' : 2}
19
20
21    rect = (0,0,1,1)
22    drawing = False
23    rectangle = False
24    rect_over = False
25    rect_or_mask = 100
26    value = DRAW_FG
27    thickness = 3
28
29    def onmouse(self, event, x, y, flags, param):
30
31        if event == cv.EVENT_RBUTTONDOWN:
32            self.rectangle = True
33            self.ix, self.iy = x,y
34
35        elif event == cv.EVENT_MOUSEMOVE:
36            if self.rectangle == True:
37                self.img = self.img2.copy()
38                cv.rectangle(self.img, (self.ix, self.iy), (x, y), self.BLUE, 2)
39                self.rect = (min(self.ix, x), min(self.iy, y), abs(self.ix - x), abs(self.iy - y))
40                self.rect_or_mask = 0
```

```

42 elif event == cv.EVENT_RBUTTONDOWN:
43     self.rectangle = False
44     self.rect_over = True
45     cv.rectangle(self.img, (self.ix, self.iy), (x, y), self.BLUE, 2)
46     self.rect = (min(self.ix, x), min(self.iy, y), abs(self.ix - x), abs(self.iy - y))
47     self.rect_or_mask = 0
48     print(" Presionar la tecla 'n' para hacer cambios \n")
49
50 # dibujar curvas de retoque
51
52 if event == cv.EVENT_LBUTTONDOWN:
53     if self.rect_over == False:
54         print("dibujar el rectangulo \n")
55     else:
56         self.drawing = True
57         cv.circle(self.img, (x,y), self.thickness, self.value['color'], -1)
58         cv.circle(self.mask, (x,y), self.thickness, self.value['val'], -1)
59
60 elif event == cv.EVENT_MOUSEMOVE:
61     if self.drawing == True:
62         cv.circle(self.img, (x, y), self.thickness, self.value['color'], -1)
63         cv.circle(self.mask, (x, y), self.thickness, self.value['val'], -1)
64
65 elif event == cv.EVENT_LBUTTONUP:
66     if self.drawing == True:
67         self.drawing = False
68         cv.circle(self.img, (x, y), self.thickness, self.value['color'], -1)
69         cv.circle(self.mask, (x, y), self.thickness, self.value['val'], -1)
70
71 def run(self):
72     # cargando imagenes
73     if len(sys.argv) == 2:
74         filename = sys.argv[1] # comenzar a dibujar
75
76     else:
77         print("No se ha introducido ninguna imagen de entrada, vuelve a cargar la imagen predeterminada, D://invll/proces
78
79         filename = 'D://invll/procesamiento imagenes/imagenes/tronco 2 51.png'

```

```

81 self.img = cv.imread(cv.samples.findFile(filename))
82 self.img2 = self.img.copy()
83 self.mask = np.zeros(self.img.shape[:2], dtype = np.uint8)
84 self.output = np.zeros(self.img.shape, np.uint8)
85
86
87 cv.namedWindow('salida')
88 cv.namedWindow('entrada')
89 cv.setMouseCallback('entrada', self.onmouse)
90 cv.moveWindow('entrada', self.img.shape[1]+10,90)
91
92 print(" Instrucciones: \n")
93 print(" Dibujar un rectangulo alrededor del objeto usando el boton derecho del mouse \n")
94
95 while(1):
96
97     cv.imshow('salida', self.output)
98     cv.imshow('entrada', self.img)
99     k = cv.waitKey(1)
100
101
102     if k == 27:
103         break
104     elif k == ord('0'):
105         print(" marcar regiones de fondo con el botón izquierdo del mouse \n")
106         self.value = self.DRAW_BG
107     elif k == ord('1'):
108         print(" Marcar las regiones de primer plano con el botón izquierdo del mouse \n")
109         self.value = self.DRAW_FG
110     elif k == ord('2'):
111         self.value = self.DRAW_PR_BG
112     elif k == ord('3'):
113         self.value = self.DRAW_PR_FG
114     elif k == ord('s'):
115         bar = np.zeros((self.img.shape[0], 5, 3), np.uint8)
116 #         res = np.hstack((self.img2, bar, self.img, bar, self.output))
117         res = np.hstack((bar, self.output))
118
119         cv.imwrite('D:/invll/procesamiento imagenes/resultado/tronco_2_51.png', res)

```

```

122         print("resetear \n")
123         self.rect = (0,0,1,1)
124         self.drawing = False
125         self.rectangle = False
126         self.rect_or_mask = 100
127         self.rect_over = False
128         self.value = self.DRAW_FG
129         self.img = self.img2.copy()
130         self.mask = np.zeros(self.img.shape[:2], dtype = np.uint8)
131         self.output = np.zeros(self.img.shape, np.uint8)
132     elif k == ord('n'):
133         print(""" Para retoques más finos, marque el primer plano y el fondo después de presionar las teclas 0-3
134         y presionar de nuevo 'n' \n""")
135         try:
136             if (self.rect_or_mask == 0):
137                 bgdmodel = np.zeros((1, 65), np.float64)
138                 fgdmodel = np.zeros((1, 65), np.float64)
139                 cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1, cv.GC_INIT_WITH_RECT)
140                 self.rect_or_mask = 1
141             elif self.rect_or_mask == 1:
142                 bgdmodel = np.zeros((1, 65), np.float64)
143                 fgdmodel = np.zeros((1, 65), np.float64)
144                 cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1, cv.GC_INIT_WITH_MASK)
145         except:
146             import traceback
147             traceback.print_exc()
148
149         mask2 = np.where((self.mask==1) + (self.mask==3), 255, 0).astype('uint8')
150         self.output = cv.bitwise_and(self.img2, self.img2, mask=mask2)
151
152         print('Done')
153
154
155 if __name__ == '__main__':
156     print(__doc__)
157     App().run()
158     cv.destroyAllWindows()

```

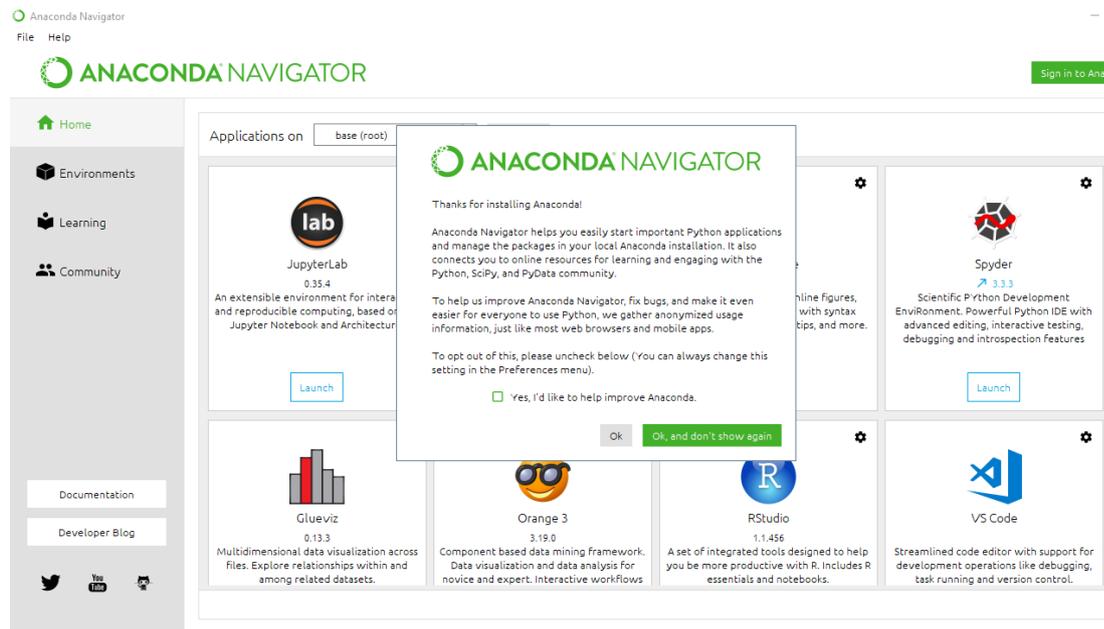
Anexo7: Código fuente escala de grises

```

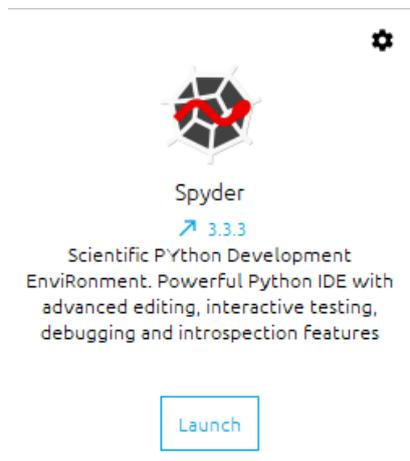
def grises():
    im = Image.open(ruta)
    im2 = im
    i = 0
    while i < im2.size[0]:
        j = 0
        while j < im2.size[1]:
            r, g, b = im2.getpixel((i, j))
            g = (r + g + b) / 3
            gris = int(g)
            pixel = tuple([gris, gris, gris])
            im2.putpixel((i, j), pixel)
            j+=1
        i+=1
    g = im2.convert('L')
    g.save('D:/invll/procesamiento imagenes/resultado/grises.gif')
    imagenL = PhotoImage(file = 'D:/invll/procesamiento imagenes/resultado/grises.gif')
    global grisesito
    grisesito = canvas.create_image(600, 150, anchor=NW, image=imagenL)
    ventana.mainloop()

```

Anexo8: Anaconda

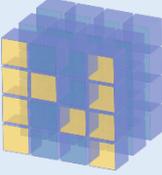
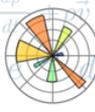


Anexo9: IDE de spyder



Spyder es un entorno de desarrollo integrado (IDE) multiplataforma de código abierto para la programación científica en el lenguaje Python. Que se incluye con anaconda.

Anexo10: Librerías de Python

Nombre	
1	 NumPy
2	 matplotlib
3	 scikit learn
4	 Pandas
5	 os Modules
6	 OpenCV
7	 imutils
8	 Seaborn

- NumPy : Acrónimo de Numerical Python. Su característica más potente es que puede trabajar con matrices (array) de n dimensiones.
- Matplotlib: es una librería de gráficos, desde histogramas, hasta gráficos de líneas o mapas de calor.
- Pandas: se utiliza para operaciones y manipulaciones de datos estructurados. Es muy habitual usarlo en la fase de depuración y preparación de los datos.
- Scikit Learn: para machine learning: Construida sobre NumPy, SciPy y matplotlib, esta librería contiene un gran número de eficientes herramientas para machine learning y modelado estadístico, como por ejemplo, algoritmos de clasificación, regresión, clustering y reducción de dimensionalidad.
- Seaborn: basada en matplotlib, se usa para hacer más atractivos los gráficos e información estadística en Python. Su objetivo es darle una mayor relevancia a las visualizaciones, dentro de las tareas de exploración e interpretación de los datos.

Anexo11: Segmentación

The screenshot shows the Spyder Python IDE interface. The main editor window displays a Python script for image segmentation. The code includes the following steps:

- Reading an image: `original = cv2.imread("tronco_1_41.png")`
- Converting to CIE Lab: `cielab = cv2.cvtColor(original, cv2.COLOR_BGR2LAB)`
- Setting the green channel to zero: `gr[:, :, 1] = 0`
- Converting to HSV: `hsv = cv2.cvtColor(gr, cv2.COLOR_BGR2HSV)`
- Defining HSV ranges for the mask: `enfermo_min = np.array([120, 255, 148])` and `enfermo_max = np.array([120, 255, 174])`
- Creating a mask: `mask = cv2.inRange(hsv, enfermo_min, enfermo_max)`
- Applying the mask: `res = cv2.bitwise_and(original, original, mask=mask)`
- Converting the result back to RGB: `final = cv2.cvtColor(res, cv2.COLOR_BGR2BGR)`
- Setting the red channel to zero: `rojo[:, :, 0] = 0`
- Printing the mean of the red channel: `print(np.mean(rojo))`

The right-hand side of the IDE shows the 'Explorador de variables' (Variable Explorer) and the 'Terminal de IPython'. The terminal displays the IPython version and the prompt `In [1]:`.

The screenshot shows the Spyder Python IDE interface, displaying the continuation of the Python script. The code includes the following steps:

- Defining HSV ranges for the mask: `enfermo_min = np.array([120, 255, 148])` and `enfermo_max = np.array([120, 255, 174])`
- Creating a mask: `mask = cv2.inRange(hsv, enfermo_min, enfermo_max)`
- Applying the mask: `res = cv2.bitwise_and(original, original, mask=mask)`
- Converting the result back to RGB: `final = cv2.cvtColor(res, cv2.COLOR_BGR2BGR)`
- Setting the red channel to zero: `rojo[:, :, 0] = 0`
- Printing the mean of the red channel: `print(np.mean(rojo))`
- Saving the original image: `guardar en excel original`
- Creating a DataFrame: `df = pd.DataFrame(rojo.reshape(-1,1))`
- Saving the DataFrame to an Excel file: `df.to_excel('caracteristicas_originales.xlsx')`
- Filtering the red channel: `rojo_filtrado = np.ma.masked_where(rojo == 0, rojo)`
- Creating a DataFrame: `df = pd.DataFrame(rojo_filtrado.reshape(-1,1))`
- Saving the DataFrame to an Excel file: `df.to_excel('caracteristicas_sin_ceros.xlsx')`
- Printing the mean of the filtered red channel: `print(np.mean(rojo_filtrado))`

The right-hand side of the IDE shows the 'Explorador de variables' (Variable Explorer) and the 'Terminal de IPython'. The terminal displays the IPython version and the prompt `In [1]:`.

Anexo12: Extracción de características

```
1 import numpy as np
2 import cv2
3 #import mahotas
4 import pandas as pd
5 from imutils import paths
6 import os
7 #import pandas as pd
8 #coger imagen en con canal B
9 def extraerMedia(imagen):
10     #Leer imagen
11     original = cv2.imread(imagen)
12     #Convertir a cielab
13     cielab = cv2.cvtColor(original, cv2.COLOR_BGR2LAB)
14     #dejar canal B
15     gr = cv2.cvtColor(cielab, cv2.COLOR_RGB2BGR)
16     gr[:, :, 1] = 0
17     gr[:, :, 2] = 0
18
19     #Pasara a HSV
20     hsv = cv2.cvtColor(gr, cv2.COLOR_BGR2HSV)
21
22     #valores max i min obtenidos:
23     #min H = 120, min S = 255, min V = 148; max H = 120, max S = 255, max V = 174
24     enfermo_min = np.array([120,255,148])
25     enfermo_max = np.array([120,255,174])
26     mask = cv2.inRange(hsv, enfermo_min, enfermo_max)
27
28     #image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
29
30
31     # Bitwise-AND mask and original image
32     res = cv2.bitwise_and(original, original, mask=mask)
33
34     #Convertir RGB
35     final = cv2.cvtColor(res, cv2.COLOR_RGB2BGR)
36     rojo = final.copy()
37     rojo[:, :, 0] = 0
38     rojo[:, :, 1] = 0
```

```
38     rojo[:, :, 1] = 0
39     rojo = np.asarray(rojo)
40     #Eliminar ceros
41     #rojo_filtrado = np.ma.masked_where(rojo == 0, rojo)
42     #Calcular La Media
43     #Llamas extraer home ep..
44     #trao media para eliminar ceros
45     media_rojo = np.mean(rojo, axis=(0, 1))
46
47     media = []
48     media.append(media_rojo[2])
49
50     return np.array(np.concatenate([media]))
51
52 ruta = "dataset/"
53 imagenRutas = list(paths.list_images(ruta))
54 total = len(imagenRutas)
55 labels = []
56 caracteristicas = []
57
58 # Loop over the input images
59 for i, imagenRutas in enumerate(imagenRutas):
60     #Leer imagen
61     vector = extraerMedia(imagenRutas)
62
63     vector_media = np.hstack([vector])
64     nombre = imagenRutas.split(os.path.sep)[-2]
65     labels.append(nombre)
66     print("Media de :"+nombre)
67     print(vector_media)
68     caracteristicas.append(vector_media)
69
70
71
72 #guardar en excel Las caracteristicas
73 df = pd.DataFrame(np.array(caracteristicas).reshape(-1,1))
74 filepath = "caracteristicas.xlsx"
75 df.to_excel(filepath, index=False)
```

Anexo13: Clasificador SVM

The screenshot shows the Spyder Python IDE interface. The main editor window displays a Python script with the following code:

```
4
5 @author: Sigueñas
6 ---
7
8 import pandas as pd
9 import numpy as np
10 #import matplotlib.pyplot as plt
11 #datos = pd.read_excel('dataset.xlsx')
12 #print(datos.columns)
13 bankdata = pd.read_excel("caracteristicass.xlsx", header=0)
14 df = pd.read_csv("test.csv", header=None, usecols=(1)).iloc[:,2:6]
15 #print(bankdata.columns)
16
17 bankdata.shape
18 bankdata.head()
19 X = bankdata.drop('etiquetas', axis=1)
20 y = bankdata['etiquetas'].values
21
22 from sklearn.model_selection import train_test_split
23 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.20)
24
25 #print("X_train")
26 #print(X_train)
27 #print("y_train")
28 #print(y_train)
29
30 np.X_train=X_train.shape[0],1]
31 np.X_test=X_test.shape[0],1]
32
33
34 from sklearn.svm import SVC
35 svclassifier = SVC(kernel='linear')
36 svclassifier.fit(X_train, y_train)
37 y_pred = svclassifier.predict(X_test)
38
39 #from sklearn.metrics import classification_report, confusion_matrix
40 from sklearn.metrics import classification_report
41 #print(confusion_matrix(y_test, y_pred))
42 #print(classification_report(y_test, y_pred))
```

The right-hand side of the IDE shows the 'Explorador de variables' (Variable Explorer) window, which is currently empty. Below it is the 'Terminal de IPython' window, which displays the standard Python 3.7.3 startup message and the prompt 'In [1]:'.

The screenshot shows the Spyder Python IDE interface with the second part of the script loaded in the editor. The code continues from the previous screenshot:

```
20 y = bankdata['etiquetas'].values
21
22 from sklearn.model_selection import train_test_split
23 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.20)
24
25 #print("X_train")
26 #print(X_train)
27 #print("y_train")
28 #print(y_train)
29
30 np.X_train=X_train.shape[0],1]
31 np.X_test=X_test.shape[0],1]
32
33
34 from sklearn.svm import SVC
35 svclassifier = SVC(kernel='linear')
36 svclassifier.fit(X_train, y_train)
37 y_pred = svclassifier.predict(X_test)
38
39 #from sklearn.metrics import classification_report, confusion_matrix
40 from sklearn.metrics import confusion_matrix
41 #print(confusion_matrix(y_test, y_pred))
42 #print(classification_report(y_test, y_pred))
43
44 import numpy as np
45 from sklearn.metrics import confusion_matrix
46 from string import ascii_uppercase
47 import seaborn as sns
48
49 confm=confusion_matrix(y_test, y_pred)
50 #print(confm)
51 columnas=[f'Clase {s}'%(i) for i in list(ascii_uppercase)[0:len(np.unique(y_pred))]]
52 df_cm=pd.DataFrame(confm,index=columnas, columns=columnas)
53
54 grafica=sns.heatmap(df_cm, cmap='Pastell1', annot=True)
55 grafica.set(xlabel='verdaderos', ylabel='predicciones')
56
57 #print(pd.crosstab(y_test, y_pred, rownames=['verdaderos'], colnames=['Predicc'], margins=True))
```

The 'Explorador de variables' window remains empty. The 'Terminal de IPython' window shows the same startup message and prompt as in the first screenshot.