

Diagnosis in cucurbits plants based on Wavelet and Fourier coefficients using support vector machines

C. A. Rivera-Romero * E. R. Palacios-Hernández **
J. U. Muñoz-Minjares * R. Olivera-Reyna *
I. A. Reyes-Portillo ***

* *Unidad Académica de Ingeniería Eléctrica Plantel Jalpa, Universidad Autónoma de Zacatecas, Jalpa, Zacatecas, México, (e-mail: c.a.riveraromero@uaz.edu.mx).*

** *Facultad de Ciencias, Universidad Autónoma de San Luis Potosí, San Luis Potosí, S. L. P. México, (e-mail: epalacios@ciencias.uaslp.mx).*

*** *Centro de Investigación y Estudios de Posgrado, Facultad de Ingeniería, Universidad Autónoma de San Luis Potosí, S. L. P., México, (e-mail: a318057@alumnos.uaslp.mx).*

Abstract:

Spectral signature analysis is one of the most widely used techniques for diagnosing diseased plants. For this, it is necessary to consider different techniques for the feature extraction that allow the identification of different damage levels of a specific pathology, such as the case of fungal disease in cucurbits plants. In this study, reflectance measurements of healthy and diseased leaves are used to identify three main stages of powdery mildew levels: leaves in the germination stage of the fungus leaves with first symptoms and diseased leaves. Then, a proposal to use frequency analysis of the spectral signatures using the Wavelet transforms and the Fourier transforms to the feature extraction from the obtained coefficients and determines the damage levels using multi-classification in support vector machine blocks. Classification accuracy of 94.6% and 98.3%, respectively, was demonstrated. Therefore, this methodology is important for the diagnosis of damage levels on cucurbits leaves and other similar plants.

keywords: Spectral signatures, feature extraction, feature vectors, classification, accuracy.

1. INTRODUCCIÓN

Las enfermedades en las plantas son uno de los problemas principales para todo tipo de cultivo y producción de alimentos. En particular, para las cucurbitáceas, una propuesta es la identificación de la cenicienta polvoriento en niveles de enfermedad, considerando desde antes de que el primer síntoma sea visible. De aquí, se deriva la importancia para crear una estrategia para el diagnóstico de la enfermedad con metodologías no destructivas. Es complicado para el ojo humano identificar patologías fúngicas antes de que aparezca un primer síntoma. Entre algunas técnicas, se encuentra el análisis espectral, utilizado para detectar problemas en la agricultura. La enfermedad de la cenicienta polvoriento en hojas de plantas puede ser notable en una la firma espectral. Esta enfermedad modifica de forma interna el contenido de clorofila en las hojas, por lo tanto, se considera que a través de un análisis de reflectancia, se logren determinar niveles de daño. Varios estudios han demostrado que

las enfermedades en las plantas se pueden identificar en función de sus características espectrales únicas (Kuska et al. (2018)). Se ha observado que la banda visible (VIS, 400 a 780 nm) muestra la composición de los pigmentos sobre las características espectrales. Así, con una firma espectral es posible describir la estimación de las concentraciones de clorofila, materia seca y agua (Kempeneers et al. (2005)). Esta firma espectral se obtiene a través de la medición del espectro de reflectancia de un punto en específico en la hoja. Para ello, es importante trabajar continuamente sobre el mismo punto de la hoja para lograr así identificar los cambios internos que produce la enfermedad.

En algunos estudios, como en Rumpf et al. (2010), se ha trabajado la detección temprana de la mancha foliar por *Cercospora*, la roya y la cenicienta polvoriento en hojas de remolacha azucarera utilizando reflectancia hiperespectral y aprendizaje automático con una precisión superior al 86%. Otra forma de caracterizar

una enfermedad es a través de imágenes. En Kumar y Prema (2015) se ha presentado una clasificación de hierbas malas basada en la textura con la transformada Wavelet, contraste, agrupamiento y homogeneidad. Se manejó la extracción de características sobre imágenes y se construyeron vectores de características obteniendo un alto grado de discriminación. Se implementó un análisis de las enfermedades de las hojas con la clasificación del tizón bacteriano del arroz y la mancha parda del arroz en las plantas de arroz. Utilizaron un clasificador lineal y las características obtenidas con la descomposición de la transformada Wavelet discreta identificando dos niveles de la enfermedad en las imágenes (Denstedt et al. (2014)). La clasificación de imágenes hiperespectrales con transformada Wavelet discreta tridimensional se utilizó en Raju et al. (2021) para extraer la información espacial y espectral en la extracción de características usando el algoritmo de k-vecinos más cercanos y las máquinas de vectores de soporte. A partir de las pruebas, se observó que el clasificador con los coeficientes de la transformada Wavelet discreta funciona mejor en términos de métricas de rendimiento, como la precisión general y el coeficiente kappa. Los estudios en cultivos susceptibles como las cucurbitáceas aún son limitados y los trabajos se enfocan más en las estructuras internas de las plantas y análisis químicos.

Para este caso, se propone la extracción de características basado en coeficientes Wavelet y de Fourier de las firmas espectrales. Estas transformadas representan espectros de reflectancia con información sobre la resolución espectral. Se propone la clasificación usando máquinas de soporte vectorial para diagnosticar los diferentes niveles de cenicienta polvorienta. Al final, se evalúan los resultados de la clasificación con parámetros de desempeño como el cálculo de la precisión y la curva de característica operativa.

2. MATERIALES Y MÉTODOS

Este estudio utiliza una base de datos de firmas espectrales obtenidas en Rivera-Romero et al. (2020) con mediciones de reflectancia de hojas con cenicienta polvorienta presentada en cuatro niveles de daño. El análisis para la distinción entre los niveles de cenicienta fue un método de segmentación de imágenes por área de enfermedad. Se consideró un total de 840 firmas espectrales, las cuales se agruparon en hojas sanas (T_1), hojas en estado de germinación del hongo (T_2), hojas con primeros síntomas (T_3) y hojas enfermas (T_4). Cada firma espectral se encuentra en un rango de 200 nm a 980 nm dentro de las longitudes de onda del rango del visible (VIS) y cercano al infrarrojo (NIR). Debido a que los espectros originales mostraron algunas irregularidades, se optó por aplicar un pre-tratamiento a través del filtro de Savitzky-Golay y la normalización sobre la media a cada firma espectral (Fig. 1).

A continuación, se encuentra el diagrama a bloques con la metodología propuesta (Fig. 2). Este trabajo presenta el

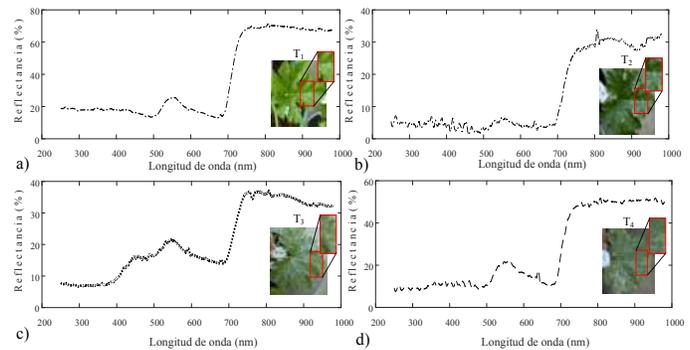


Fig. 1. Firmas espectrales con pre-tratamiento: a) T_1 - hojas sanas, b) T_2 - hojas en estado de germinación del hongo, c) T_3 - hojas con primeros síntomas, y d) T_4 - hojas enfermas.

diagnóstico de la cenicienta polvorienta en niveles de daño en las hojas de cucurbitáceas a través de la caracterización de la reflectancia espectral.

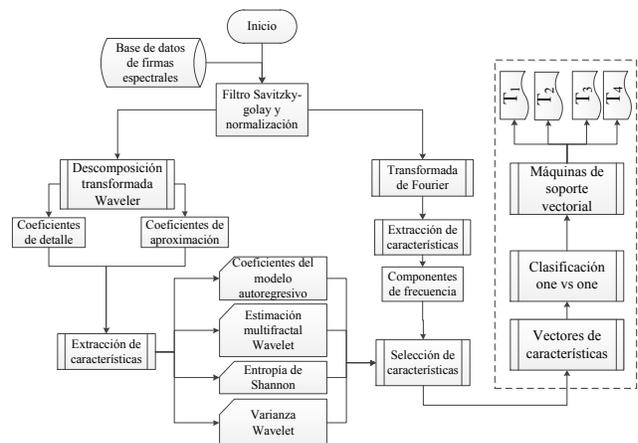


Fig. 2. Metodología propuesta para el diagnóstico de niveles en la cenicienta polvorienta.

2.1 Extracción de características

La transformada discreta de ondulitas (conocida como transformada discreta Wavelet, DWT) es una serie ortonormal en tiempo (T). El resultado son coeficientes asociados con un tiempo y una escala diádica particular como uno o más coeficientes. Las escalas de tiempo presentan datos de baja frecuencia y las escalas de tiempo pequeñas brindan información de alta frecuencia sobre la serie de tiempo. Una transformada Wavelet tiene filtros de dos canales: paso bajo y paso alto. Los coeficientes de aproximación se obtienen en cada escala por el filtro de paso bajo (LoF) y los coeficientes de detalle por el filtro de paso alto (HiF) (Denstedt et al. (2014); Raju et al. (2021)). Para este trabajo, se tienen las firmas espectrales de longitud N (2856 muestras) con una resolución de 0,33 intervalos para cada longitud

de onda. Se calcularon dos conjuntos de coeficientes, los coeficientes de aproximación denominados A_c y los coeficientes de detalle D_c (Rivera-Romero et al. (2021)). La serie y su DWT son dos representaciones de la misma entidad matemática. El número de coeficientes creados es el mismo que el número de observaciones en la serie. Además, se agrega la superposición máxima de la transformada wavelet (maximal overlap discrete wavelet transform, MODWT) que conserva todos los tiempos posibles en cada escala. El filtro Wavelet de superposición de nivel j y de longitud L_j y el signo X_t es un parámetro discreto del proceso estocástico definido por:

$$W_{j,t} \equiv \sum_{l=0}^{L_j} \tilde{h}_{j,t} X_{t-l} \quad (1)$$

filtrando X_t con la superposición $\tilde{h}_{j,l}$ y su estado finito, j th la varianza y la escala diádica j :

$$\sum_{j=1}^{\infty} v_X^2(\tau_j) = var(X_t) \quad (2)$$

Así, la varianza wavelet se descompone del proceso estocástico sobre las escalas. El algoritmo de superposición implementa la convolución cíclica en el dominio del tiempo y en el dominio de Fourier. Se aplica la transformada de Fourier discreta inversa (discrete Fourier transform, DFT) para calcular el nivel j^{th} y los coeficientes del filtro. H_k denota la longitud de la onda MODWT y G_k el filtro de escala. Sea j el nivel, N el tamaño de la muestra. Se realizó un análisis de resolución múltiple (multi-resolution analysis, MRA) para una serie de tiempo dada, el MODWT se utilizó con los coeficientes de detalle y suavizado vinculado con un filtro de fase cero para alinear el resultado como características en el MRA con la serie de tiempo original. El MRA de una serie de tiempo se expresa como:

$$X_t = \sum_{j=1}^J d_j + s_J \quad (3)$$

donde d_j es el detalle de onda (serie de coeficientes de la onda inversa a escala j) y s_J es la serie uniforme que es la inversa de la serie de coeficientes de escala. De forma específica, para la extracción de características, se usó la familia de transformadas Wavelet con la función Haar y Daubechies. La DWT brinda una representación completa de los datos espectrales al filtrar recursivamente la señal con un filtro de paso alto y bajo. Esta transformación separa los detalles locales en diferentes resoluciones y características (West et al. (2007)). En otro caso, y para métodos comparativos de transformadas, se agregó la extracción de características con la transformada discreta de Fourier (discrete Fourier transform, DFT). Con este algoritmo se calculó la primera dimensión de una matriz de entrada N_D . La entrada k^{th} del canal de salida L^{th} , $y(k,L)$, es igual al punto k^{th} del punto M de la DFT del canal de entrada L^{th} .

$$y(k, L) = \sum_{p=1}^P u(p, L) e^{-j2\pi(p-1)(k-1)/M} \quad (4)$$

Los resultados de las magnitudes de la DFT se calcularon con los coeficientes de cada componente de la señal en el dominio de la frecuencia (Rivera-Romero et al. (2021)). Los datos de magnitud tienen valores reales y es posible utilizar la ventaja de que la señal tiene componentes uniformes para lograr alguna reducción de datos. Las características aplican varios cálculos de los coeficientes de Wavelet derivados de las firmas espectrales observadas, de modo que el modelo resulta de las correlaciones entre los coeficientes Wavelet en rangos espectrales superpuestos y en escalas adyacentes (Feng et al. (2015)). Para la extracción de características, se propone obtener las aproximaciones y los coeficientes de detalle como un conjunto de escalas y compensaciones para cada señal. Después, se configuran las siguientes características extraídas en ocho bloques formados con una ventana de 2856 muestras divididas entre 357 para obtener bloques de cada señal descritos a continuación.

- Para el modelo auto-regresivo, cada ventana se estiman mediante el método Burg. Es un método de bloques que estima la densidad espectral de potencia (power spectral density, PSD) de la trama de entrada. Estos métodos consisten en ajustar un modelo auto-regresivo (AR) a la señal por mínimos cuadrados de los errores de predicción hacia adelante y atrás. Este modelo se utiliza en otros métodos de selección para determinar los coeficientes proporcionados con el mejor ajuste para formas de onda en problemas de clasificación (Leonarduzzi et al. (2010)).
- Se calculó una medida teórica de la entropía de Shannon (SE), con la transformada Wavelet que viene dada por:

$$SE_j = - \sum_{k=1}^N p_{j,k} * \log p_{j,k} \quad (5)$$

donde N es el número de coeficientes correspondientes en el nodo j^{th} y $p_{j,k}$ son los cuadrados normalizados de los coeficientes Wavelet en el nodo terminal j^{th} .

- Se calcularon dos medidas fractales con los coeficientes Wavelet para usar como características. Se utiliza el ancho de un espectro singular obtenido del preámbulo como medida de las propiedades multifractales de la señal espectral. El segundo índice de escala acumulativo es el valor seleccionado. Este es un índice basado en una escala que se utiliza para describir el comportamiento de la ley de potencia de las señales a diferentes resoluciones. En segundo lugar, consideramos el rango de exponentes de Holder (EH), que son los segundos acumulativos en general que representan la salida de los exponentes de escala de la linealidad (Li y Zhou (2016)).
- A través de toda la señal, se calculó la varianza Wavelet (WVAR). Los resultados son las medidas de la variabilidad de la señal proporcionalmente dentro del intervalo de frecuencia de la banda (Li y Zhou (2016)).

Una vez obtenidos las características, partiendo de la transformada Wavelet, se continuó con el uso de la transformada discreta de Fourier para cambiar las 2856 muestras en el dominio de la frecuencia en vectores de 1025 coeficientes. El objetivo fue reducir los datos a un conjunto de características mucho más pequeño (Li y Zhou (2016)).

2.2 Formación de vectores de características

Para la formación de vectores, se obtuvo, un total de setenta y seis funciones calculadas, dieciséis funciones AR, treinta y dos valores SE, dieciséis estimaciones fractales, ocho para SP y ocho para valores HR, y doce estimaciones de WVAR. Tres conjuntos de datos de características con matrices donde cada fila es un vector de características para los datos espectrales correspondientes. Los datos de vectores de características creados se reducen de 2856 muestras a 76 para los componentes Wavelet y 1025 elementos que parten de los coeficientes de Fourier. Las características Wavelets se etiquetaron en un segundo conjunto de datos con 840 x 76 y 76 características. Los coeficientes del dominio de la frecuencia se calcularon con matrices de 840 x 1025 en otro conjunto de datos.

2.3 Clasificación de los niveles de daño

Una vez que se tienen las características, se procede a la parte de la clasificación. Para este trabajo, se propone el uso de máquinas de soporte vectorial (SVM) no lineal, en las cuales requieren de un núcleo (kernel) y valores apropiados para sus parámetros. El objetivo es construir un hiperplano óptimo que minimice y estime el parámetro h mediante $h_{est} = R^2||w||^2 + 1$, donde R es el diámetro de la esfera más pequeña que incluye a todos los datos de entrenamiento y $||w||$ es la norma Euclidiana del vector de pesos. Los datos de entrada en cada SVM deben pertenecer a dos clases diferentes. Por lo tanto para que una SVM clasifique correctamente se eligen los parámetros que minimizan Γ (intervalo de confianza) y h trabajando con diferentes valores de acuerdo al núcleo. Al tener problemas con más de dos clases, es necesario considerar un problema de multclasificación. Por lo tanto, se construyeron bloques de clasificadores binarios y a esto se le conoce como el método uno versus uno (one versus one, OVO), en donde se considera el número de clases (k) y el número de bloques con clasificadores se determina de acuerdo a $k(k-1)/2$ Rumpf et al. (2010). Los bloques se construyeron en pares de clases (T_1 vs T_2 , T_1 vs T_3 , T_1 vs T_4 , T_2 vs T_3 , T_2 vs T_4 , T_3 vs T_4), con un total de seis clasificadores binarios, uno para cada par de clases. Entonces, se procedió al entrenamiento de los datos.

Cada clasificador se entrenó con los vectores de características pertenecientes a dos clases distintas. Se realizó una serie de entrenamientos con los diferentes núcleos. Para este estudio, se trabajó con el núcleo derivado de una función polinomial de grado tres. Los

datos se dividieron de forma aleatoria en dos conjuntos: conjuntos de datos de entrenamiento (70%) y de prueba (30%). De las 840 firmas espectrales y los coeficientes Wavelet y Fourier calculados, se tomó el conjunto con los datos de entrenamiento. Ahora que los datos se redujeron a la formación de vectores de características para cada señal. El siguiente paso es utilizar estos vectores de características para clasificar los datos espectrales.

Se realizaron dos análisis. Primero se utilizó todo el conjunto de datos (conjuntos de entrenamiento y pruebas) y se estimó la tasa de clasificación errónea de los niveles (T_1 , T_2 , T_3 y T_4). Para cada proceso de clasificación, se obtuvo la matriz de confusión utilizando la validación cruzada entre niveles. En una tarea de clasificación, la precisión de una clase es el número de resultados positivos correctos dividido por el total de resultados etiquetados de cada clase. En otras palabras, de todos los registros que el clasificador asigna a una etiqueta determinada, qué proporción pertenece realmente a la clase. El valor de recuperación se define como el número de etiquetas correctas dividido por el número de etiquetas de una clase determinada. Por lo tanto, como resultado de la evaluación del clasificador y el diagnóstico, se proporciona una métrica que resume el rendimiento del clasificador en términos de precisión de diagnóstico para los niveles de daño.

3. RESULTADOS

Después de un número de pruebas con los diferentes núcleos en los clasificadores, se concluyó que las SVM con la función de polinomial de grado tres, resultaron el mejor clasificador binario para identificar los niveles de daño con todas las características. Así, un conjunto de características basadas en los coeficientes de las transformadas Wavelet y de Fourier resultaron una opción para el diagnóstico de los niveles de daño en plantas cucurbitáceas con enfermedad fúngica. Esto se logró comprobar al someter vectores de características en un sistema de clasificación. Al ejecutarse el último módulo de multclasificación, el sistema de diagnóstico dió los resultados finales que se presentan en gráficas con los vectores de datos resultantes clasificados. Las Figuras 3 y 4 presentan los resultados de los vectores de características de prueba para para el diagnóstico. En estas gráficas se observa cada uno de los datos caracterizados en los diferentes niveles de daño y la salida como resultado de la clasificación. Los datos que no lograron ser diagnosticados se resaltan fuera del nivel correspondiente y se visualiza el nivel en el que esa hoja fue diagnosticada.

A partir de los datos clasificados, se creo una matriz de confusión que parte del problema de múltiples clases. La matriz formada $n \times m$, en donde las filas se nombran según las clases reales y las columnas como las clases previstas. Esta matriz muestra cuándo una clase es asignada con otra. La diagonal principal contiene la suma de todas las predicciones correctas con porcentajes en conjunto con el número de datos pertenecientes a esa

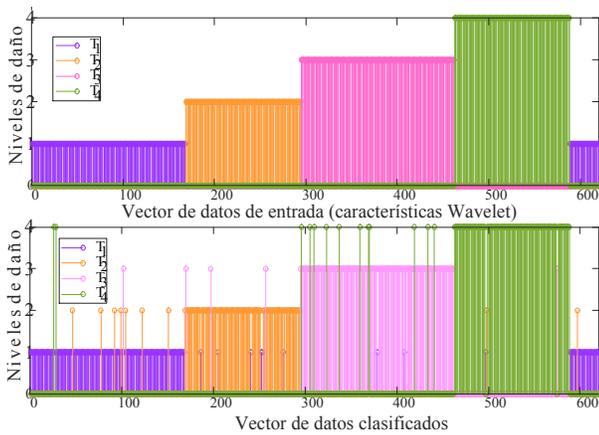


Fig. 3. Vectores de características Wavelets clasificados en cuatro niveles de daño (T_1 , T_2 , T_3 , y T_4)

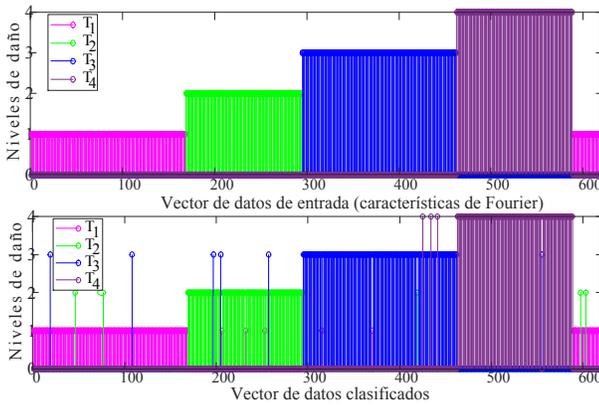


Fig. 4. Vectores de características de Fourier clasificados en los cuatro niveles de daño (T_1 , T_2 , T_3 , y T_4)

clase. También se puede observar, en la Figura 5 y en la Figura 6, al final de la diagonal principal (recuadro azul) el total del porcentaje de datos acertados en sus clases correspondientes. Se observa que el diagnóstico de datos clasificados con las características Wavelets total es de un 94.6% de precisión, mientras que las características de Fourier dieron una mejor clasificación con un porcentaje de 98.3%. En la Figura 5 y la Figura 6, se observan los porcentajes de cada nivel bien diagnosticado y su porcentaje y datos erróneos. Una de las problemáticas de mayor importancia en la agricultura, es la detección temprana de una enfermedad. Existen las propuestas que diagnostican las plantas y diferentes enfermedades, sin embargo, una etapa previa a los síntomas no es de fácil detección. En este estudio, se diagnostica un primer nivel de daño, que es T_2 y es un nivel predictivo a la enfermedad, lo cual permite que en esta etapa se consideren aplicar tratamientos menos dañinos o de prevención para el cultivo. En este nivel, se obtuvo un 94.9% con características Wavelets y un 97.8% con Fourier, lo cual indica que la enfermedad se puede detectar en tiempo para aplicar un buen control preventivo. Las curvas de característica operativa

Datos clasificados (T_1, T_2, T_3, T_4)	1	234 27.9%	1 0.1%	2 0.2%	0 0.0%	98.7% 1.3%
	2	3 0.4%	177 21.1%	1 0.1%	0 0.0%	97.8% 2.2%
	3	2 0.2%	1 0.1%	236 28.1%	3 0.4%	97.5% 2.5%
	4	0 0.0%	0 0.0%	1 0.1%	179 21.3%	99.4% 0.6%
		97.9% 2.1%	98.9% 1.1%	98.3% 1.7%	98.4% 1.6%	98.3% 1.7%
	Datos etiquetados (T_1, T_2, T_3, T_4)					

Fig. 5. Matriz de confusión de los datos Wavelets clasificados en niveles de daño.

Datos clasificados (T_1, T_2, T_3, T_4)	1	228 27.1%	7 0.8%	1 0.1%	4 0.5%	95.0% 5.0%
	2	8 1.0%	169 20.1%	1 0.1%	0 0.0%	94.9% 5.1%
	3	3 0.4%	1 0.1%	224 26.7%	14 1.7%	92.6% 7.4%
	4	1 0.1%	1 0.1%	4 0.5%	174 20.7%	96.7% 3.3%
		95.0% 5.0%	94.9% 5.1%	97.4% 2.6%	90.6% 9.4%	94.6% 5.4%
	Datos etiquetados (T_1, T_2, T_3, T_4)					

Fig. 6. Matriz de confusión de los datos de Fourier clasificados en niveles de daño.

del receptor (receiver operating characteristic, ROC) presentan una herramienta para evaluar el rendimiento de un modelo de clasificación. En ellas se observa la relación entre la tasa de verdaderos positivos (true positive rate, TPR) y la tasa de falsos positivos (false positive rate, FPR) del modelo de clasificación. TPR describe la tasa a la que el clasificador predice como “positivo” a las muestras que si pertenecen a esa clase. FPR describe la tasa a la que el clasificador predice como “positivo” a las muestras que no pertenecen a esa clase (Figura 7).

Los resultados obtenidos en este trabajo son óptimos al lograr diagnosticar una hoja partiendo de su firma espectral con una enfermedad fúngica. En comparación con la mayoría de los estudios con plantas y análisis espectral, se han presentado otro tipo de características. Por ejemplo, en Luo et al. (2013) examinó 48 características espectrales derivadas de índices de vegetación para detectar la densidad de áfidos en la hoja de trigo a través de una comparación entre diferentes

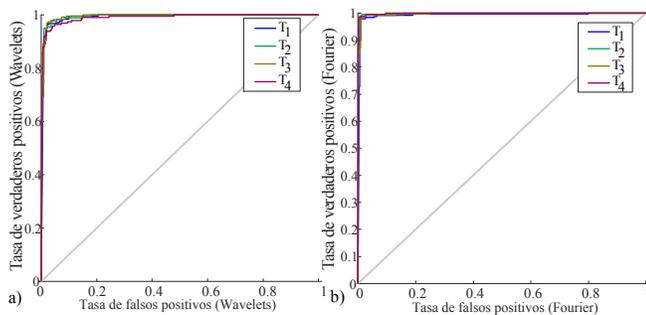


Fig. 7. Curvas de característica operativa (ROC) de evaluación de los niveles de daño clasificados con las características a) Wavelets y b) Fourier.

métodos de transformación espectral de derivación, transformación de eliminación continua y transformación Wavelet continua.

El conjunto de características espectrales sensibles de infestación de áfidos estuvo compuesto por 17 muestras, y se estableció un modelo de detección en áfidos con un coeficiente de determinación (R^2) de 0.77. Los autores en Bajwa et al. (2017) informan que los modelos discriminantes lineales en datos espectrales pudieron identificar plantas sanas y plantas enfermas con el nematodo del quiste de la soja a través de los índices de vegetación calculados. Obtuvieron un modelo de análisis discriminante de enfermedades con un valor de 80% de precisión en plantas sanas y 58% en plantas infestadas. Todos estos trabajos pueden detectar los síntomas, pero no existe un estadio previo de una enfermedad, si no sólo la identificación de varias enfermedades.

4. CONCLUSIONES

Mediante la metodología propuesta, se logró diagnosticar el estado de plantas cucurbitáceas con respecto a la cenicilla polvorienta, partiendo de la caracterización de los datos frecuenciales de las firmas espectrales. Con este trabajo, se puede considerar una ventaja el uso de firmas espectrales en comparación con las imágenes por razones de tiempo de procesamiento de datos, tanto en los algoritmos empleados para la extracción de características como en la clasificación.

La extracción de características utilizando los coeficientes resultantes con las transformaciones diagnosticó los niveles propuestos T_1 , T_2 , T_3 y T_4 . Además, considerando que uno de los niveles importantes es la primera etapa de la enfermedad (T_2) cuando la germinación del hongo aún no es visible y se obtuvo un 97.8% para su clasificación. Considerando el tipo de datos que son los coeficientes de las transformadas en combinación con las máquinas de soporte vectorial, es posible comparar para buscar métodos de extracción de características más simples y determinar su eficiencia a través de la clasificación. En trabajos futuros, estos resultados son una continuidad a la aplicación de técnicas para el diagnóstico

en otras enfermedades y diferentes cultivos con métodos no destructivos.

REFERENCIAS

- Bajwa, S., Rupe, J., y Mason, J. (2017). Soybean disease monitoring with leaf reflectance. 9, 127.
- Denstedt, M., Bjorgan, A., Milanic, M., y Randeberg, L.L. (2014). Wavelet based feature extraction and visualization in hyperspectral tissue characterization. *Biomedical Optics Express*, 5.
- Feng, S., Duarte, M.F., y Parente, M. (2015). Universality of wavelet-based non-homogeneous hidden markov chain model features for hyperspectral signatures. In *2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 19–27.
- Kempeneers, P., De Backer, S., Debruyne, W., Coppin, P., y Scheunders, P. (2005). Generic wavelet-based hyperspectral classification applied to vegetation stress detection. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 610–614.
- Kumar, A. y Prema, P. (2015). A study on weed discrimination through wavelet transform, texture feature extraction and classification. *International Journal of Computer Science and Information Technology*, 7.
- Kuska, M.T., Bohnenkamp, D., Brugger, A., Alisaac, E., Wahabzada, M., Behmann, J., y Mahlein, A.K. (2018). Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. *Journal of Plant Diseases and Protection*, 125(5), 5–20.
- Leonarduzzi, R., Schlotthauer, G., y Torres, M.E. (2010). Wavelet leader based multifractal analysis of heart rate variability during myocardial ischaemia. *IEEE Engineering in Medicine and Biology Society*, 2010, 110–3.
- Li, T. y Zhou, M. (2016). Ecg classification using wavelet packet entropy and random forests. *Entropy*, 18, 285.
- Luo, J., Huang, W., Zhao, J., Zhang, J., Zhao, C., y Ma, R. (2013). Detecting aphid density of winter wheat leaf using hyperspectral measurements. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal*, 6, 690–698.
- Raju, A., Veni, S., y Jagatheesan, A. (2021). Robust classification technique for hyperspectral images based on 3d-discrete wavelet transform. *Remote Sensing*, 13, 1255.
- Rivera-Romero, C.A., Palacios-Hernández, E.R., Morales-Saldaña, J.A., y Olivera-Reyna, R. (2021). Feature extraction of powdery mildew levels in cucurbits leaves using wavelet-based and fourier transforms. In *2021 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, volume 5, 1–6.
- Rivera-Romero, C.A., Palacios-Hernández, E.R., Trejo-Durán, M., Olivera-Reyna, R., y Morales-Saldana, J.A. (2020). Visible and near-infrared spectroscopy for detection of powdery mildew in Cucurbita pepo L. leaves. 14(4), 1–19.
- Rumpf, T., Mahlein, A.K., Steiner, U., Oerke, E.C., Dehne, H.W., y Plümer, L. (2010). Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture*, 74(1), 91 – 99.
- West, T., Prasad, S., y Bruce, L.M. (2007). Multiclassifiers and decision fusion in the wavelet domain for exploitation of hyperspectral data. In *2007 IEEE International Geoscience and Remote Sensing Symposium*, 4850–4853.