



DOI: [https://doi.org/10.37811/cl\\_rcm.v6i6.3742](https://doi.org/10.37811/cl_rcm.v6i6.3742)

## Aprendizaje basado en coeficientes de fourier para la identificación de daño en plantas de cultivos

**Claudia Angélica Rivera-Romero**

[c.a.riveraromero@uaz.edu.mx](mailto:c.a.riveraromero@uaz.edu.mx)

<https://orcid.org/0000-0003-2874-5533>

**Reynel Olivera-Reyna**

[reynel@uaz.edu.mx](mailto:reynel@uaz.edu.mx)

<https://orcid.org/0000-0002-7964-3986>

**Jorge Ulises Muñoz-Minjares**

[ju.munoz@uaz.edu.mx](mailto:ju.munoz@uaz.edu.mx)

<https://orcid.org/0000-0001-8097-9551>

**Miguel Angel Navarrete-Sánchez**

[mnavarrete@uaz.edu.mx](mailto:mnavarrete@uaz.edu.mx)

<https://orcid.org/0000-0002-0876-1424>

**Roberto Olivera-Reyna**

[roliverar@uaz.edu.mx](mailto:roliverar@uaz.edu.mx)

<https://orcid.org/0000-0002-0340-9560>

Unidad Académica de Ingeniería Eléctrica Plantel Jalpa,  
Universidad Autónoma de Zacatecas  
Zacatecas, México

## RESUMEN

El análisis de firmas espectrales es uno de los métodos de diagnóstico más utilizados para identificar enfermedades en las plantas. Con este fin, se deben considerar diferentes técnicas de adquisición de información para detectar los diferentes niveles de una enfermedad o plaga en particular, como en el caso de las enfermedades fúngicas. En este estudio, se consideraron plantas cucúrbitas en las cuales se identificaron tres etapas de niveles de una enfermedad fúngica que son las hojas en la etapa de germinación del hongo, hojas con primeros síntomas y hojas enfermas. Se utilizó una base de datos con firmas espectrales de hojas de calabacita. A continuación, se propone el análisis de frecuencia de las características espectrales utilizando la transformada de Fourier para extraer características de los coeficientes obtenidos y partir de bloques de clasificación con máquinas de vectores de soporte para la estimación del nivel de daño. Se demostraron precisiones de clasificación del 98.3%. Por lo tanto, este método se puede utilizar para diagnosticar el grado de daño en diferentes cultivos.

**Palabras clave:** *firmas espectrales; extracción de características; vectores de características; clasificación; desempeño.*

Correspondencia: [c.a.riveraromero@uaz.edu.mx](mailto:c.a.riveraromero@uaz.edu.mx)

Artículo recibido 1 octubre 2022 Aceptado para publicación: 1 noviembre 2022

Conflictos de Interés: Ninguna que declarar

Todo el contenido de **Ciencia Latina Revista Científica Multidisciplinar**, publicados en este sitio están disponibles bajo

Licencia [Creative Commons](https://creativecommons.org/licenses/by/4.0/) 

Cómo citar: Rivera-Romero, C. A., Olivera-Reyna, R., Muñoz Minjares, J. U., Navarrete-Sánchez, M. A., & Olivera-Reyna, R. (2022). Aprendizaje basado en coeficientes de fourier para la identificación de daño en plantas de cultivos. *Ciencia Latina Revista Científica Multidisciplinar*, 6(6), 2921-2936. [https://doi.org/10.37811/cl\\_rcm.v6i6.3742](https://doi.org/10.37811/cl_rcm.v6i6.3742)

## Fourier coefficient-based learning for damage identification in crop plants

### ABSTRACT

Spectral signature analysis is one of the most widely used diagnostic methods to identify plant diseases. To this end, different information acquisition techniques must be considered to detect the different levels of a particular disease or pest, as in the case of fungal diseases. In this study, cucurbit plants were considered in three stages of levels of a fungal disease were identified which are leaves in the fungal germination stage, leaves with first symptoms, and diseased leaves. A database with spectral signatures of zucchini leaves was used. Then, frequency analysis of spectral features is proposed using Fourier transform to extract features from the obtained coefficients and from classification blocks with support vector machines for damage level estimation. Classification accuracies of 98.3% were demonstrated. Therefore, this method can be used to diagnose the damage levels in different crops.

**Keywords:** *spectral signatures; feature extraction; feature vectors; classification; performance.*

## INTRODUCCIÓN

Las enfermedades de las plantas en cultivos se definen como uno de los principales problemas en todas las formas de cultivo y producción de alimentos. Especialmente para las calabazas, se recomienda identificar la cenicilla polvorienta al nivel de la enfermedad antes de que aparezcan los primeros síntomas. A partir de esto, se puede ver la importancia de utilizar métodos no destructivos para desarrollar estrategias de diagnóstico de enfermedades. Los daños en plantas por hongos son difíciles de reconocer de forma previa por el ojo humano, y esto se hace una vez que ya aparecen los primeros síntomas. Algunas de las técnicas incluyen el análisis espectroscópico, que se utiliza para detectar problemas agrícolas. Las enfermedades fúngicas en las hojas de las plantas se pueden identificar a través de una firma espectral. La enfermedad cambia internamente el contenido de clorofila de las hojas, por lo que se considera que el análisis de reflectancia puede determinar la extensión del daño. Varios estudios han demostrado que las enfermedades de las plantas se pueden identificar en función de sus señales espectrales únicas (Kuska et al. (2018)). Se ha demostrado que el rango de longitud de onda visible (VIS, 400 a 780 nm) ha mostrado el efecto de la composición del pigmento sobre las propiedades espectrales. Por lo tanto, las estimaciones de las concentraciones de clorofila, materia seca y agua (Kempeneers et al. (2005)) se pueden describir utilizando características espectrales en un punto específico de la hoja. Para ello, es importante trabajar constantemente en la misma zona de la hoja para identificar los cambios internos provocados por la enfermedad.

Algunos estudios, como Rumpf et al. (2010), utilizaron la reflectancia hiperespectral y el aprendizaje automático para detectar la mancha foliar por *Cercospora*, la roya y la cenicilla polvorienta en las hojas de la remolacha azucarera con una precisión superior al 86 %. Otra forma de describir la enfermedad es a través de imágenes. En Kumar y Prema (2015) se presenta la clasificación de malezas basada en la textura con transformada wavelet, contraste, agrupamiento y homogeneidad. Se procesa la extracción de características de la imagen y se construyen vectores de características, logrando un alto poder de discriminación. Las enfermedades foliares de las plantas de arroz se analizaron y clasificaron en bronceado bacteriano del arroz y mancha marrón del arroz. Utilizan un

clasificador lineal y características obtenidas mediante la descomposición por transformada de wavelet discreta para identificar dos niveles de enfermedad en las imágenes (Denstedt et al. (2014)). Además, la transformada de wavelet discreta tridimensional también ha sido utilizada en la clasificación de imágenes hiperespectrales (Raju et al. (2021)), considerando la información espacial y espectral en la extracción de objetos utilizando el algoritmo del  $k$  vecino más cercano y máquinas de vectores de soporte. Para este trabajo, se consideró el análisis sobre cultivos de cucurbitáceas, centrándose más en la estructura interna de la planta y los análisis químicos.

Por lo tanto, se propone una extracción de características basada en características espectrales con los coeficientes de la transformada de Fourier en comparación con la transformada Wavelet. Estas transformaciones representan espectros de reflectancia con información de resolución espectral. Además, se propone el uso de la clasificación de máquinas de vectores de soporte para diagnosticar diferentes niveles de daño en hojas de cucurbitáceas con la enfermedad de la cenicilla polvorienta. Finalmente, se propone la evaluación de los resultados de la clasificación utilizando parámetros de desempeño como estimaciones de precisión y curvas de rendimiento.

## **METODOLOGÍA**

Usando la base de datos de firmas espectrales obtenidas por Rivera-Romero et al. (2020), este estudio analizó las mediciones de reflectancia en hojas de cucurbitáceas infectadas con cenicilla polvorienta visualizadas en cuatro niveles de daño. Se consideraron un total de 840 firmas espectrales entre hojas sanas ( $T_1$ ), hojas con germinación fúngica ( $T_2$ ), hojas con primeros síntomas ( $T_3$ ) y hojas enfermas ( $T_4$ ). Cada característica espectral se encuentra entre 200 nm y 980 nm en los rangos de longitud de onda visible (VIS) e infrarrojo cercano (NIR). Como había algunas irregularidades en los espectros sin procesar, se decidió realizar un procesamiento a través de un filtro Savitzky-Golay y realizar una normalización de la media para cada función espectral (Figura 1). A continuación, se muestra el diagrama de bloques del método propuesto (Figura 2).

Figura 1 Firmas espectrales procesadas: a) T1- hojas sanas, b) T2- hojas en estado de germinación del hongo, c) T3- hojas con primeros síntomas, y d) T4- hojas enfermas.

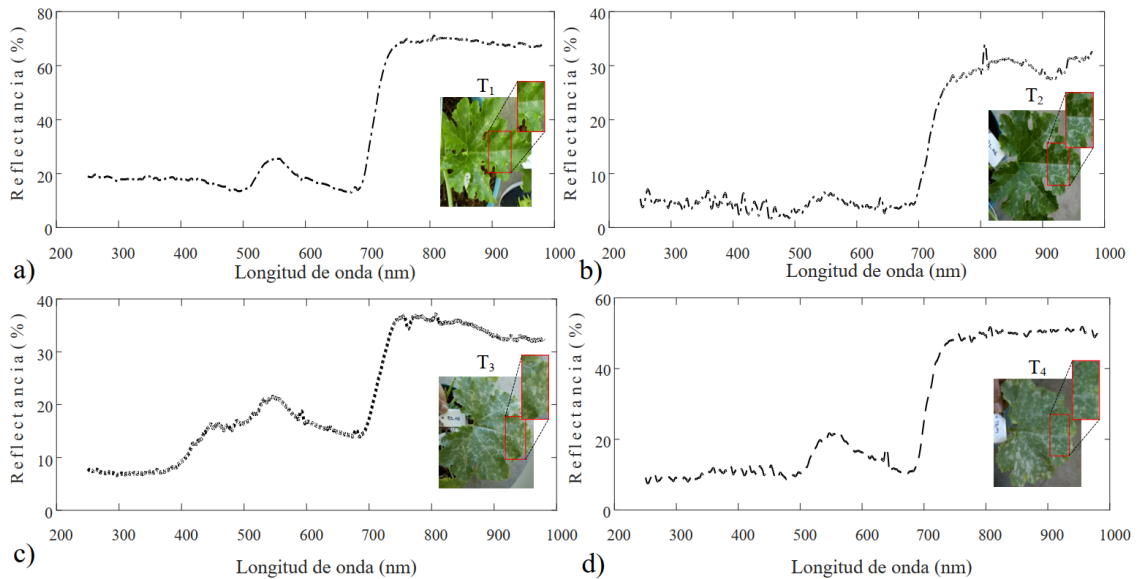
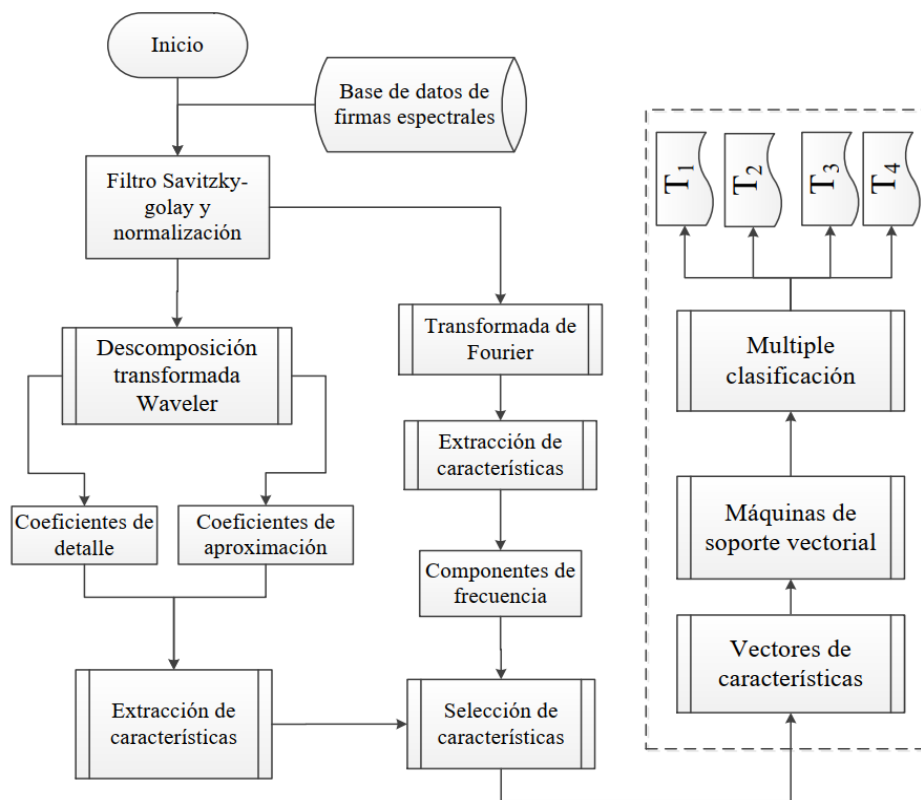


Figura 2 Metodología propuesta para el diagnóstico de niveles en la cenicilla polvorienta.



---

### Extracción de características

En este caso, se realizó la extracción de características usando la transformada discreta de Fourier (DFT). Este algoritmo calcula la primera dimensión de la matriz de entrada de los datos espectrales. El resultado de la magnitud DFT se calculó mediante los coeficientes de cada componente de la señal en el dominio de la frecuencia (Rivera-Romero et al. (2021)). Cada firma espectral contiene un total de 2856. Para este trabajo contamos con características espectrales de  $N$  longitud (2856 muestras) con una resolución de 0.33 intervalos para cada longitud de onda. El resultado del uso de la DFT en cada firma espectral es en el dominio de la frecuencia, un vector con 1025 coeficientes. Reduciendo los datos a un conjunto más pequeño de características.

Con fines comparativos entre diferentes tipos de características, se consideró la extracción de características a través de implementar la Transformada Wavelet Discreta (DWT) es una serie de tiempo ortogonal ( $T$ ), solo para los primeros coeficientes. El resultado es el coeficiente asociado a un tiempo binario dado, escalado a uno o más factores. Las escalas de tiempo representan datos de baja frecuencia y las escalas de tiempo pequeñas proporcionan información de alta frecuencia sobre la serie de tiempo. La transformada wavelet tiene dos filtros de canal: paso bajo y paso alto. Los coeficientes de aproximación para cada escala se obtienen con un filtro de paso bajo (LoF), y los coeficientes de detalle se obtienen con un filtro de paso alto (HiF) (Denstedt et al. (2014); Raju et al. (2021)). Debido a que los datos de amplitud son valores reales y se puede lograr la reducción de los datos usando la señal para que tenga componentes iguales. Estas funciones realizan múltiples cálculos sobre los coeficientes de wavelet derivados de las características espectrales observadas, de modo que el modelo genera correlaciones entre los coeficientes de wavelet en regiones espectrales superpuestas y escalas adyacentes (Feng et al. (2015)). Para la extracción de características con los componentes wavelet, se propuso obtener aproximaciones y factores de detalle como escala y compensación para cada señal. Las funciones resultantes se configuraron en ocho bloques de una ventana de 2856 muestras divididas por 357 para obtener bloques para cada señal que se describe a continuación.

Se calculan dos conjuntos de coeficientes: coeficientes de aproximación denominados  $A_c$  y coeficientes de detalle  $D_c$  (Rivera-Romero et al. (2021)). Una serie y su DWT son dos representaciones de la misma entidad matemática. Además, se agregó una transformada

de wavelet discreta de superposición máxima, que conserva todos los tiempos posibles en cada escala. El algoritmo de superposición implementa la convolución circular en los dominios del tiempo y de Fourier. Por lo tanto, se utilizó de nuevo la transformada de Fourier discreta inversa (DFT) para calcular  $j$  pasos y los coeficientes de filtro. También, se ajustó un modelo autorregresivo (*AR*) a la señal utilizando errores de predicción de mínimos cuadrados. Este modelo se utiliza en otros métodos de selección para determinar los coeficientes que mejor se ajustan a la forma de onda en una tarea de clasificación (Leonarduzzi et al. (2010)). Para modelos autorregresivos, cada ventana se estimó utilizando el método de Burg. Es un método de bloque para estimar la densidad espectral de potencia de una trama de entrada generando valores de potencia espectral (*PS*). Se calculó una medida teórica de la entropía de Shannon (*SE*), considerando  $N$  como el número de coeficientes correspondientes en el nodo  $j$ -ésimo y  $p(j,k)$  es el cuadrado normalizado del coeficiente wavelet en el nodo terminal  $k$ -ésimo. A esta caracterización, se agregó el cálculo de dos medidas fractales como funciones usando los coeficientes wavelet. Después, se consideró una serie de exponentes de Holder (*HR*), que representan la salida exponencial de la escala lineal (Li y Zhou (2016)). Y, por último, se consideró la varianza de wavelet (*WVAR*) para toda la señal. El resultado final son los componentes wavelet como medida de la variabilidad de la señal escalada en todo el rango de frecuencias de la banda.

#### **Formación de vectores de características**

Para la vectorización se generaron vectores de 1025 elementos a partir de los coeficientes de Fourier. Y para la parte comparativa con los coeficientes wavelet, se obtuvieron un total de 76 características computacionales, 16 características *AR*, 32 valores *SE*, 16 cálculos fractales, 8 valores *SP*, 8 valores *HR*, y 12 cálculos *WVAR*. Tres conjuntos de datos propios con matrices donde cada fila es un vector propio correspondiente a los datos espectrales. Los datos de vectores propios generados se reducen de 2856 muestras a 76 componentes de onda. Los componentes wavelet en el segundo conjunto de datos están etiquetados como características de  $840 \times 76$  y  $76$ . El cálculo de los coeficientes de dominio de frecuencia para el conjunto con características de Fourier es una matriz de  $840 \times 1025$ .



## Clasificación de daño

Una vez obtenidas las características, se procedió con el proceso de la clasificación de niveles de daño. Se propusieron las máquinas de vectores de soporte no lineales (SVM). El objetivo es crear un hiperplano óptimo que minimice y estime el parámetro  $h$  con  $hest=R2/||w||2+1$ , donde  $R$  es el diámetro de la esfera más pequeña incluyendo todos los datos de entrenamiento,  $||w||$  es la norma euclidiana del vector de peso. Los datos de entrada para cada SVM deben pertenecer a dos clases diferentes. Por lo tanto, para que la SVM se clasifique correctamente, los parámetros que minimiza  $\Gamma$  (intervalo de confianza) y  $h$  se eligen utilizando diferentes valores según el núcleo. Si hay más de dos categorías de clases, se deben considerar problemas de clasificación múltiple. Por lo tanto, se construyó un bloque de clasificadores binarios con el método uno versus uno (OVO) considerando el número de clases ( $k$ ) y el número de bloques clasificadores de acuerdo con  $k(k-1)/2$  (Rumpf et al. (2010)). Los grupos se formaron a partir de pares de categorías ( $T_1$  versus  $T_2$ ,  $T_1$  versus  $T_3$ ,  $T_1$  versus  $T_4$ ,  $T_2$  versus  $T_3$ ,  $T_2$  versus  $T_4$ ,  $T_3$  versus  $T_4$ ), considerando seis clasificadores binarios, uno para cada par de clases. Al tener definido los bloques de clasificadores binarios, se procedió, al entrenamiento de los datos.

Cada clasificador se entrena con vectores de características que pertenecen a dos clases diferentes. Se realizaron varias sesiones de entrenamiento en diferentes núcleos. En este estudio, se usó un núcleo derivado de una función polinomial de tercer orden. Los datos se dividieron aleatoriamente en dos grupos: conjuntos de datos de entrenamiento (70%) y datos de prueba (30%). El conjunto de datos de entrenamiento se obtuvo a partir de las 840 características espectrales con los coeficientes de Fourier y otros conjuntos con los componentes wavelet.

Se realizaron dos análisis, uno con los coeficientes de Fourier y el segundo con los componentes Wavelet. Primero, se utilizó todo el conjunto de datos (entrenamiento y prueba) y se evaluaron las tasas de clasificación errónea de cada nivel. Se obtuvo una matriz de confusión para cada proceso de clasificación mediante validación cruzada entre niveles. En una tarea de clasificación, la precisión de la clase es el número de positivos correctos dividido por el número total de resultados etiquetados para cada clase. Es decir, qué fracción de todas las entidades a las que el clasificador asignó una determinada etiqueta pertenece realmente a esa clase. La precisión se define como el número de etiquetas correctas dividido por el número de etiquetas en una clase dada. Por lo tanto,

la evaluación y el diagnóstico del clasificador dieron como resultado una métrica que resume el desempeño del clasificador en términos de precisión de diagnóstico del nivel de daño.

## RESULTADOS Y DISCUSIÓN

Después de varias pruebas con diferentes vectores de datos en el clasificador, se concluyó que el SVM con función polinomial cúbica era el mejor clasificador binario para identificar los niveles de daño con todas las características. Por lo tanto, un conjunto de características basadas en los coeficientes de Fourier y los componentes Wavelet permiten diagnosticar el grado de enfermedades fúngicas en las cucurbitáceas. Esto se verifica enviando vectores de características al sistema de clasificación. Cuando se ejecuta el último módulo de clasificación múltiple, el sistema de diagnóstico informa los resultados finales, que se representan gráficamente mediante los vectores de datos de clasificación generados. La Figura 3 y la Figura 4, muestran los resultados de los vectores de características de prueba utilizados para el diagnóstico. Estas figuras son pruebas de los vectores de datos caracterizados por diferentes niveles de daño y salida como resultado de la clasificación. Los datos que fallan en el diagnóstico se resaltan fuera de la jerarquía adecuada y muestran la jerarquía en la que se diagnosticó la hoja de forma correcta.

**Figura 3** Vectores de componentes Wavelets clasificados en los niveles  $T_1$ ,  $T_2$ ,  $T_3$ , y  $T_4$ .

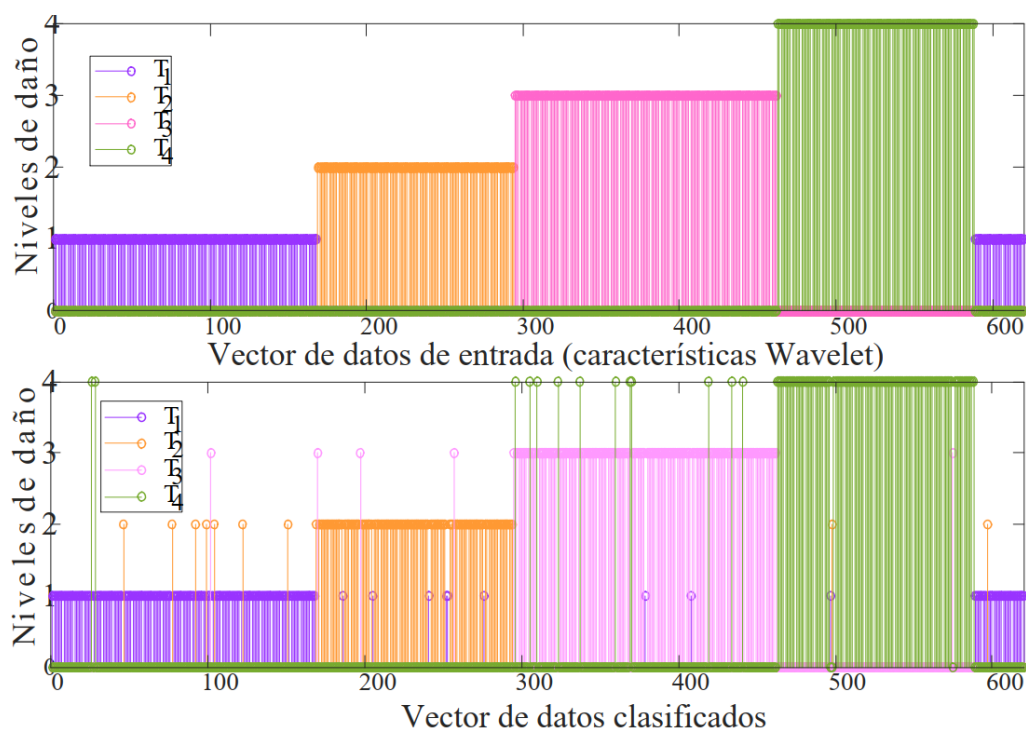
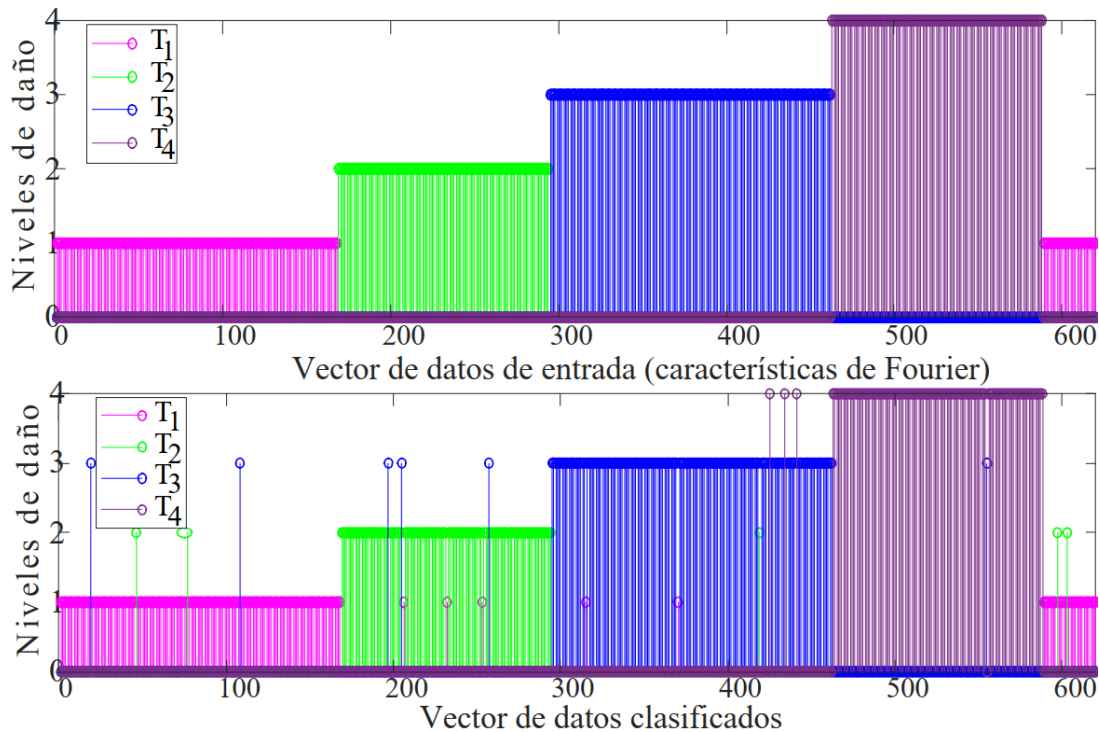


Figura 4

Vectores de coeficientes de Fourier clasificados en los niveles  $T_1$ ,  $T_2$ ,  $T_3$ , y  $T_4$ .



Se construyó una matriz de confusión a partir de los datos categóricos, comenzando con la pregunta multiclase. La matriz es  $n \times m$ , donde las filas llevan el nombre de la clase real y las columnas llevan el nombre de la clase esperada. Esta matriz muestra cuándo una clase se asigna a otra. La diagonal principal contiene el porcentaje de todas las predicciones correctas y el número de datos que pertenecen a esa clase. También se puede observar que en la Figura 5 y la Figura 6, al final de la diagonal principal (recuadro azul) se indica el porcentaje total de datos correctos en la clase respectiva. Se observó que la precisión diagnóstica de los datos clasificados con los vectores de características con componentes Wavelet tuvo un total fue de 94.6%, mientras que el rendimiento de clasificación de los coeficientes de Fourier fue mejor con 98.3% y el porcentaje de cada nivel de diagnóstico correcto, así como su porcentaje y datos de error.

Figura 5 Matriz de confusión de los componentes 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 ( $T_1, T_2, T_3, T_4$ )					

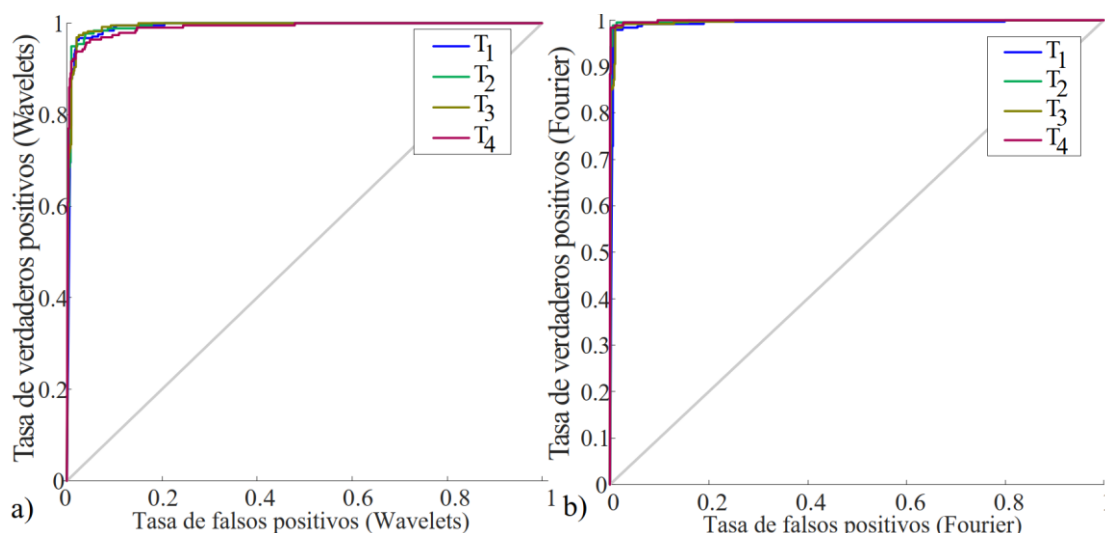
Figura 6 Matriz de confusión de los coeficientes de Fourier clasificados en niveles de daño.

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 ( $T_1, T_2, T_3, T_4$ )					

Las curvas de características operativas del receptor (ROC) proporcionan una herramienta para evaluar el rendimiento de los modelos de clasificación. Muestran la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR) para un modelo de clasificación. TPR describe la velocidad a la que un clasificador predice

muestras que pertenecen a esa clase como "positivas". FPR describe la tasa a la que el clasificador predice muestras fuera de clase como "positivas" (Figura 7).

**Figura 7** Curvas de característica operativa (ROC) de evaluación de los niveles de daño clasificados con las características: a) componentes Wavelets y b) coeficientes de Fourier.



Los resultados obtenidos en este trabajo son óptimos en el diagnóstico de enfermedades fúngicas foliares en base a sus características espectrales. En comparación con la mayoría de los estudios de análisis botánico y espectral, se han mostrado otros tipos de características. Por ejemplo, en Luo et al. (2013), se estudiaron 48 características espectrales extraídas de un índice de vegetación para determinar la densidad de áfidos en hojas de trigo mediante la comparación de diferentes transformadas espectrales derivadas, transformada de eliminación y wavelet.

La característica espectral sensible para la infestación de áfidos constaba de 17 muestras y se estableció un modelo de detección de áfidos con un coeficiente de detección  $R^2$  de 0.77. Los autores de Bajwa et al. (2017), informaron que un modelo discriminante lineal de datos espectrales pudo identificar plantas sanas de aquellas infectadas con el nematodo del quiste de la soja utilizando un índice de vegetación calculado. Obtuvieron un modelo de análisis discriminante de enfermedades con una precisión del 80% para plantas sanas y del 58% para plantas infectadas. Todo esto funciona para revelar los síntomas, pero no para encontrar las etapas iniciales de la enfermedad. Su enfoque se sitúa en identificar varias enfermedades a la vez.

Uno de los problemas más importantes en la agricultura es la detección oportuna de enfermedades. Existen pautas para diagnosticar enfermedades de las plantas y otras enfermedades, pero las etapas antes de los síntomas no son fáciles de determinar. En este estudio se diagnosticó el primer nivel de daño  $T_2$ , y este es el nivel esperado de enfermedad que permite considerar tratamientos menos dañinos o preventivos para los cultivos en esta etapa. En este nivel se obtiene el 94.9% de signos de onda y el 97.8% de signos de Fourier, lo que indica que las enfermedades se pueden detectar a tiempo para una buena prevención y control.

### **CONCLUSIONES**

Usando el método propuesto, el estado de cenicienta de las plantas de las cucurbitáceas se puede diagnosticar en función de las características de los datos de frecuencia de características espectrales. A través de este trabajo, el uso de características espectrales puede considerarse una ventaja sobre las imágenes en los algoritmos de clasificación y extracción de características debido al tiempo de procesamiento de datos.

La extracción de características utilizando los coeficientes obtenidos y las transformaciones diagnostican los niveles propuestos considerando hojas sanas, hojas en estado de germinación de la enfermedad fúngica, y hojas enfermas. Además, se considera uno de los niveles más importantes por tratarse de la primera etapa de la enfermedad, que es el tiempo de la germinación del hongo, con un alto nivel de precisión. Al considerar los tipos de datos como coeficientes de transformación en combinación con máquinas de vectores de soporte, es posible buscar comparativamente métodos de extracción de características más simples y determinar su efectividad en la clasificación. Sin embargo, los resultados presentados en este trabajo son aceptables en el nivel de que el proceso es simple. En el trabajo futuro, estos resultados son una continuación de la aplicación de métodos no destructivos en las técnicas de diagnóstico que pueden ser utilizados para el diagnóstico de otras enfermedades y en diferentes cultivos.

---

**LISTA DE REFERENCIAS**

- Bajwa, S., Rupe, J., & Mason, J. (2017). Soybean disease monitoring with leaf reflectance. *Remote Sensing*, 9, 127. <https://doi.org/10.3390/rs9020127>
- Denstedt, M., Bjorgan, A., Milanic, M., & Randeberg, L.L. (2014). Wavelet based feature extraction and visualization in hyperspectral tissue characterization. *Biomedical Optics Express*, 5. <https://doi.org/10.1364/BOE.5.004260>
- Feng, S., Duarte, M. F., & 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. <https://doi.org/10.1109/CVPRW.2015.7301379>
- Kempeneers, P., De Backer, S., Debruyne, W., Coppin, P., & Scheunders, P. (2005). Generic wavelet-based hyperspectral classification applied to vegetation stress detection. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 610-614. <https://doi.org/10.1109/TGRS.2004.839545>
- Kumar, A. & 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. <https://doi.org/10.5121/ijcsit.2015.7304>
- Kuska, M. T., Bohnenkamp, D., Brugger, A., Alisaac, E., Wahabzada, M., Behmann, J., & 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. <https://doi.org/10.1007/s41348-017-0124-6>
- Leonarduzzi, R., Schlotthauer, G., & Torres, M.E. (2010). Wavelet leader based multifractal analysis of heart rate variability during myocardial ischaemia. *IEEE Engineering in Medicine and Biology Society*, 2010, 110-123. <https://doi.org/10.1109/IEMBS.2010.5626091>
- Li, T. & Zhou, M. (2016). Ecg classification using wavelet packet entropy and random forests. *Entropy*, 18, 285. <https://doi.org/10.3390/e18080285>
- Luo, J., Huang, W., Zhao, J., Zhang, J., Zhao, C., & 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. <https://doi.org/10.1109/JSTARS.2013.2248345>

- Raju, A., Veni, S., & Jagatheesan, A. (2021). Robust classification technique for hyperspectral images based on 3d-discrete wavelet transform. *Remote Sensing*, 13, 1255. <https://doi.org/10.3390/rs13071255>
- Rivera-Romero, C. A., Palacios-Hernández, E. R., Morales-Saldaña, J. A., & 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. <https://doi.org/10.1109/ROPEC53248.2021.9668078>
- Rivera-Romero, C. A., Palacios-Hernández, E. R., Trejo-Durán, M., Olivera-Reyna, R., & Morales-Saldana, J.A. (2020). Visible and near-infrared spectroscopy for detection of powdery mildew in Cucurbita pepo L. leaves. *14(4)*, 1-19. <https://doi.org/10.1117/1.JRS.14.044515>
- Rumpf, T., Mahlein, A.K., Steiner, U., Oerke, E.C., Dehne, H.W., & 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. <https://doi.org/10.1016/j.compag.2010.06.009>
- West, T., Prasad, S., & 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. <https://doi.org/10.1109/IGARSS.2007.4423947>