

Procesamiento de imágenes para la detección de enfermedades causadas por hongos en cucurbitáceas

C. A. Rivera-Romero* E. R. Palacios-Hernández**
M. Trejo-Durán*** R. Olivera-Reyna****
J. A. Morales-Saldaña†

* *Centro de Investigación de Estudios de Posgrado, Universidad Autónoma de San Luis Potosí, S.L.P., México (e-mail: c.a.riveraromero@alumnos.uaslp.edu.mx).*

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

*** *Departamento de Estudios Multidisciplinarios, DICIS, Universidad de Guanajuato, Gto., México (e-mail: mtrejo@ugto.mx).*

**** *Unidad Académica de Ingeniería Eléctrica, Universidad Autónoma de Zacatecas, Zac., México (e-mail: roliverar@uaz.edu.mx).*

† *Facultad de Ingeniería, Universidad Autónoma de San Luis Potosí, S.L.P., México (e-mail: jmorales@uaslp.mx).*

Resumen: Las cucurbitáceas son plantas muy susceptibles a enfermedades fúngicas como la cenicienta polvorienta (CP) que reduce la producción de los cultivos causando pérdidas económicas. A partir de un estudio fenológico e inspección visual en hojas de plantas de Cucurbita pepo L. (C. pepo L.), se proponen cuatro niveles de daño de la CP: T_1 -hoja sana, T_2 -hoja con esporas en germinación, T_3 -hoja con primeros síntomas y T_4 -hoja enferma. Se trabajó con una base de datos compuesta de 76,778 muestras de imágenes pre-procesadas obtenidas de cinco cultivos de cucurbitáceas pertenecientes a lugares y temporadas diferentes. Se propone una metodología basada en el cálculo de la matriz de co-ocurrencia de color (GLCM) y descriptores de textura (DTs) de las muestras de imágenes en base a dos algoritmos. El primer algoritmo es para la extracción y selección de características y el segundo para la clasificación de los cuatro niveles de daño. Se trabajó con una serie de pruebas estadísticas y con dos clasificadores binarios, el algoritmo del k-vecino más cercano (KNN) y las máquinas de soporte vectorial (SVM). Los resultados demostraron la habilidad de los descriptores de textura de diagnosticar una enfermedad fúngica.

Palabras clave: Matriz de Co-ocurrencia de Color, Descriptores de Textura, Prueba de Lilliefors, Análisis de Varianza, Prueba de Tukey, Clasificación.

1. INTRODUCCIÓN

La agricultura es uno de los recursos primordiales de la economía que involucra una gran comunidad de plantas en varios cultivos basados en las condiciones ambientales de cada lugar. Sin embargo, los agricultores se enfrentan cada día a un gran número de problemas como lo son las enfermedades en las plantas. Es necesario la identificación del daño a tiempo para incrementar la productividad en los cultivos. La mayoría de las enfermedades en las plantas se detectan por los síntomas visibles en las hojas (Barbedo (2014)). Existe un gran número de métodos que utilizan imágenes para la clasificación de enfermedades y plagas, (Pydipati et al. (2006)). En estos casos, los tipos de agentes pueden ser identificados, sin embargo,

en algunos casos el problema ya no puede ser controlado. Por lo tanto, se puede trabajar en la extracción de características de las hojas para encontrar un punto de prevención. La identificación de niveles de daño a través del procesamiento de imágenes de las hojas de una planta no es una tarea sencilla debido a la variabilidad de características que se van presentando de acuerdo al desarrollo de la planta. Por ello, a través del monitoreo y análisis previos de las hojas de cinco cultivos de plantas de Cucurbita pepo L. (C. pepo L.) en condiciones, lugares y temporadas diferentes, se obtuvieron cuatro niveles de daño (diagnósticos) para la cenicienta polvorienta (CP): T_1 - hojas sanas, T_2 - hojas con esporas en germinación, T_3 - hojas con primeros síntomas y T_4 - hojas enfermas. En la Fig. 1, se presenta una inspección

visual de las imágenes contenidas en una base de datos. La metodología propuesta para el diagnóstico se enfoca en el procesamiento y caracterización de las imágenes para identificar los niveles de daño de la cenicilla polvorienta en las hojas de *C. pepo* L.

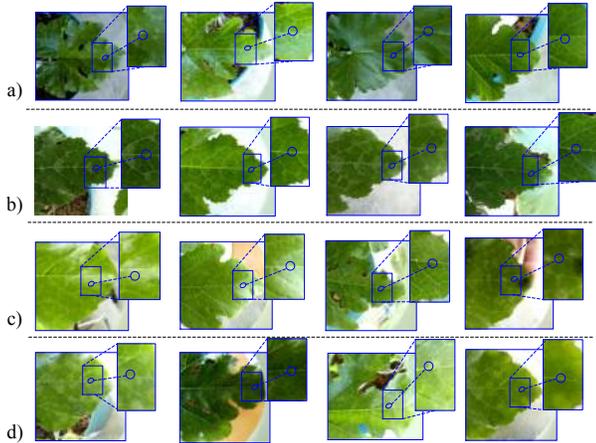


Fig. 1. Inspección visual de las imágenes de las hojas de *C. pepo* L. con cuatro niveles de daño de la enfermedad de cenicilla polvorienta: a) T_1 - hojas sanas, b) T_2 - hojas con esporas en germinación, c) T_3 - hojas con primeros síntomas, y d) T_4 - hojas enfermas.

2. DEFINICIÓN DE PROBLEMA

Se considera que las hojas de *C. pepo* L. muestran diferentes características cuando hay un agente fúngico. Por lo tanto, el problema a resolver parte de proponer una metodología compuesta de algoritmos para detectar automáticamente los niveles de daño considerando características extraídas de muestras de imágenes. La cenicilla polvorienta aparece generalmente en la floración y el desarrollo del fruto. Cuando una espора se establece en la hoja, existe un periodo de germinación del hongo de tres a siete días. Después, los primeros síntomas se hacen visibles que son pequeñas manchas blancas circulares llenas de esporas en las hojas hasta cubrirse completamente (Yuan et al. (2012)).

3. METODOLOGÍA

Se cuenta con una base de datos definida con 76,778 muestras de imágenes pre-procesadas de regiones de hojas (lóbulo superior central) pertenecientes a cinco cultivos en temporadas y condiciones diferentes (Fig. 1). Se realizó un análisis de los niveles de daño de la CP a través de la inspección visual de las hojas, estadios fenológicos de las plantas y de la aparición de síntomas. Se proponen cuatro niveles de daño: T_1 , T_2 , T_3 y T_4 , descritos anteriormente. Las muestras tienen una resolución de 200×200 megapíxeles. Se cuenta con un total de 46,930 muestras para T_1 ; 9,880 para T_2 ; 9,542 para T_3 y 10,426 para T_4 . Las muestras están divididas

en imágenes de componentes de color (CC): nivel de gris (Gray (G)), RGB (Red (R), Blue (BB) y Green (GG)), HSV (Hue (H), Saturation (S) y Value (V)), L^*a^*b (Luminance (L), chrominance *a (A), chrominance *b (B)) y YCbCr (Luma component (Y), chroma blue difference (CB), y chroma red difference (CR)). El diagnóstico se realiza a través de una metodología propuesta formada por dos algoritmos. Un primer algoritmo es implementado para la extracción y selección de características. En este algoritmo se realiza el cálculo de la matriz de co-ocurrencia de color (GLCM) para obtener los descriptores de textura (DTs) de las muestras de imágenes y formar una base de datos de características. Después, estos resultados fueron sometidos a una serie de pruebas estadísticas para finalmente obtener una base de datos de características seleccionadas. Un segundo algoritmo se implementó con clasificadores binarios y un esquema de voto para la clasificación de datos. En la Fig. 2, se presenta el diagrama de la metodología propuesta para identificar los niveles de daño.

3.1 Algoritmo para la extracción y selección de características

Se consideraron 22 descriptores de textura (DTs) con sus nombres originales en inglés (Tabla 1) (Haralick et al. (1973)). Como la CP decolora las hojas, los DTs se relacionan con los aspectos de color. La tabla 1 contiene las ecuaciones de los DTs usados para la caracterización. En la Fig. 3 se describe a detalle el algoritmo para la extracción y selección de características. El cálculo de la matriz de co-ocurrencia de niveles de grises (GLCM, Gray level color matrix) se hizo con los 255 niveles de gris (Mattonen et al. (2014)). Las muestras de la base de datos se encuentran separadas por CCs, por lo tanto, cada una de las características se etiquetó con el nombre de la característica seguido de un paréntesis indicando a que CC pertenece esa muestra (ejemplo: $Dissi(CR)$, el descriptor Disimilitud perteneciente al componente CR del espacio de color YCbCr). Se obtuvo una nueva base de datos con un total de 286 características resultantes de calcular $22 \text{ DTs} \times 13 \text{ CC}$.

Para la selección de características (Fig. 3), primero se efectuó una prueba de Lilliefors para verificar la normalidad de los datos, en la cual se descartaron 64 características. Sobre 222 características restantes se realizó un análisis de varianza (ANOVA) para comprobar la hipótesis de que las medias ($\mu_x = \mu_y$) de dos o más conjuntos de datos entre diagnósticos son iguales (Rossi and Mirtchev (2016)). Los valores de significancia como F y el p -valor fueron obtenidos. Después, se aplicó una prueba de Tukey a cada par de niveles de daño ($T_1 - T_2$, $T_1 - T_3$, $T_1 - T_4$, $T_2 - T_3$, $T_2 - T_4$, y $T_3 - T_4$). Los resultados indicaron que sólo 53 características resultaron ser significativamente diferentes entre los cuatro niveles de daño. A partir de estos resultados, considerando

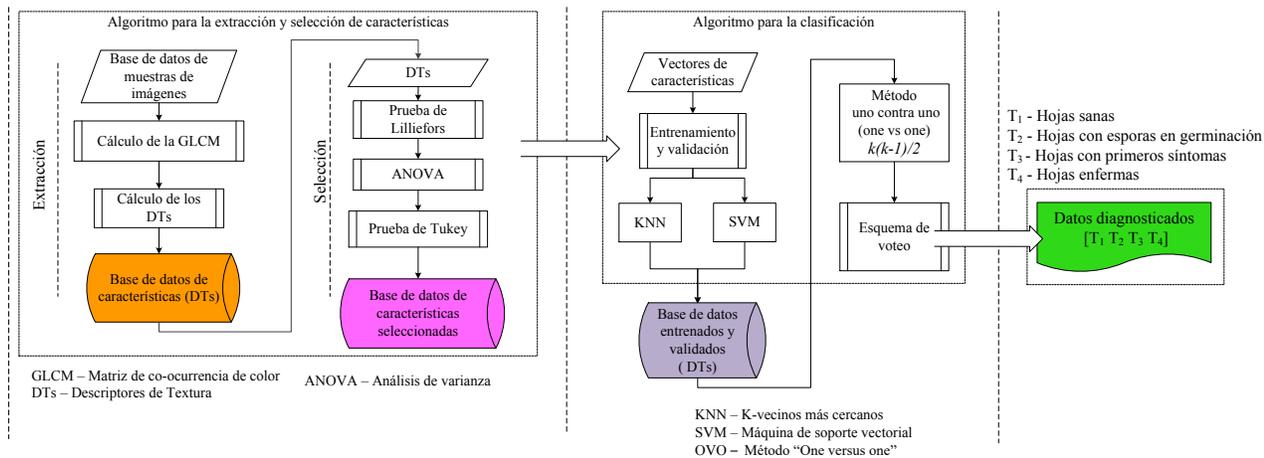


Fig. 2. Metodología propuesta para identificar los niveles de daño de CP en hojas de *C. pepo* L.

Tabla 1. Ecuaciones para el cálculo de los descriptores de textura (Haralick et al. (1973), Pydipati et al. (2006), Mattonen et al. (2014), Brynolfsson et al. (2017)) y el resultado de la prueba de Tukey en donde se listan las características y los componentes de color con la habilidad de separar los cuatro niveles de daño de la CP.

Ecuación	Espacios de color					Descriptores de textura (DTs)
	Gris	RGB	HSV	LAB	YCbCr	
$Auto = \sum_{i,j} p(i,j)$		GG	V			Autocorrelación
$Contr = \sum_{i,j} \ i-j\ ^2 p(i,j)$	G	RGG		LA	YCR	Contraste
$Corrm = \sum_{i,j} \frac{\{i \times j\} \times p(i,j) - \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y}$				L	Y	Correlación ₁
$Corrp = \sum_{i,j} \frac{\{i \times j\} \times p(i,j) - \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y}$						Correlación ₂
$Cprom = \sum_{i,j} \{i+j - \mu_x - \mu_y\}^4 \times p(i,j)$		GG				Prominencia del grupo
$Cshad = \sum_{i,j} \{i+j - \mu_x - \mu_y\}^3 \times p(i,j)$						Matiz del grupo
$Dissi = \sum_{i,j} \ i-j\ \cdot p(i,j)$	G	BB		L	Y	Dissimilitud
$Energ = \sum_{i,j} p(i,j)^2$	G	RGG	V			Energía
$Entr = - \sum_{i,j} p(i,j) \log_2(p(i,j))$		R	S			Entropía
$Homom = \sum_{i,j} \frac{1}{1-(i-j)^2} p(i,j)$	G	R			Y	Homogeneidad ₁
$Homop = \sum_{i,j} \frac{1}{1-(i-j)^2} p(i,j)$						Homogeneidad ₂
$Maxpr = \max_{i,j} p(i,j)$						Probabilidad máxima
$Sosvh = \sum_{i,j} (i - \mu)^2 p(i,j)$			V			Suma de cuadrados
$Savgh = \sum_{i,j} i p_{x+y}(i)$	G			L		Suma del promedio
$Svarh = \sum_{i,j} (i-j)^2 p(i,j)$			V			Suma de varianza
$Senh = - \sum_{i,j} p_{x+y}(i) \log(p_{x+y}(i))$		R				Suma de entropía
$Dvarh = \sum_{i,j} (k - \mu_x - \mu_y)^2 p_{x-y}(k)$	G	R		A	CBCR	Diferencia de la varianza
$Denth = - \sum_{i,j} p_{x+y}(i) \log_2(p_{x+y}(i))$			S	A		Diferencia de la entropía
$Inf1h = \frac{HXY - HXY1}{\max(HX, HY)}$		BB				Medida de la información de la correlación ₁
$Inf2h = \sqrt{1 - \exp[-2(HXY2 - HXY)]}$						Medida de la información de la correlación ₂
$Indnc = \sum_{i,j} \{i-j\}^2 \times p(i,j)$						Diferencia inversa normalizada
$Idmnc = \sum_{i,j} \frac{1}{1+(i-j)^2} p(i,j)$	G	RGG		A	YCR	Momento de diferencia inversa normalizado

GG indica el componente de color verde (Green) y BB indica el componente azul (Blue) de RGB, respectivamente.

$\mu_x, \mu_y, \sigma_x, \sigma_y$ son las medias y las desviaciones estándar de p_x y p_y .

$HXY = entr$, donde HX y HY son las entropías de p_x y p_y .

$HXY1 = - \sum_{i,j} p(i,j) \log\{p_x(i)p_y(j)\}$ y $HXY2 = - \sum_{i,j} p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}$.

el valor de significancia F del resultado del ANOVA, ordenados de forma ascendente, se formaron grupos de seis vectores con seis características cada uno: F_a, F_c, F_e, F_g , en donde de acuerdo al valor de significancia. Los cuatro diagnósticos corresponden a la combinación de seis características pertenecientes a componentes de diferentes

espacios de color. Un segundo grupo de vectores (F_d, F_f, F_v) fue formado con características pertenecientes a componentes del mismo espacio de color y considerando el orden del valor de significancia de F . Un total de 13,110 datos \times 6 características entre los cuatro niveles de daño

Tabla 2. Resultado de la prueba de Tukey: las primeras 24 características con la habilidad de separar los cuatro niveles de daño de la CP y su valor de significancia F con un p valor < 0.0001 .

DTs/ F_a	F	DTs/ F_c	F	DTs/ F_e	F	DTs/ F_g	F
1. Dissi(BB)	23.61	7. Autoc(V)	66.42	13. Entro(R)	78.04	19. Dvarh(CR)	96.08
2. Dissi(Y)	37.31	8. Denth(S)	68.00	14. Homom(R)	81.11	20. Contr(CR)	96.38
3. Inflh(BB)	38.39	9. Svarh(V)	68.28	15. Idmnc(R)	93.56	21. Idmnc(Y)	96.71
4. Dissi(L)	39.04	10. Savgh(L)	70.52	16. Idmnc(CR)	95.14	22. Idmnc(G)	97.14
5. Dissi(G)	40.12	11. Sosvh(V)	71.47	17. Dvarh(R)	95.43	23. Idmnc(GG)	97.26
6. Senth(R)	52.72	12. Savgh(G)	72.54	18. Contr(R)	95.43	24. Contr(Y)	103.93

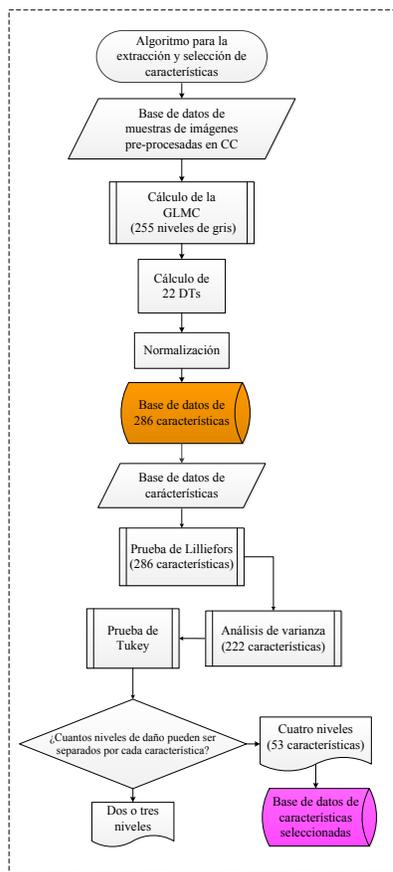


Fig. 3. Descripción del algoritmo para la extracción y selección de características.

se consideró para formar la base de datos de vectores de características.

3.2 Algoritmo para la clasificación

Se propusieron dos clasificadores binarios: *k-vecinos más cercanos* (KNN, k-nearest neighbors) y *máquinas de soporte vectorial* (SVM, support vector machine). El clasificador KNN se implementó con la distancia Euclidiana (Moldagulova and Sulaiman (2017)). El clasificador SVM se entrenó con varios núcleos como el lineal, polinomial, sigmoidal y al final con la función Gaussiana de base radial (RBF) y con el 40% del total de los datos de cada vector. En la Fig. 4, se presenta el hiperplano óptimo del resultado del entrenamiento de una SVM con RBF de las características $Dissi(BB)$ y $Senth(R)$ en los niveles de daño T_3 y T_4 . Ambos

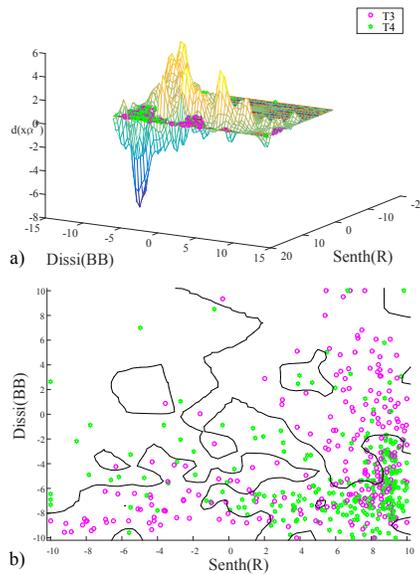


Fig. 4. Hiperplano óptimo del resultado de entrenamiento de una SVM con RBF.

clasificadores se validaron con el 20% de los datos. Para resolver el problema de clasificación se binarizaron las clases por pares (Rumpf et al. (2010)). Al final los resultados se combinan con el método de *uno contra uno* (OVO, *one versus one*). En la Fig. 5 se presenta la descripción de este algoritmo.

4. PRUEBAS

Al conocer las características y los componentes de color que muestran la habilidad de separar los cuatro niveles de daño se realizaron una serie de pruebas con el 40% de los datos restantes. Por cada vector de características se realizaron nueve pruebas con ambos clasificadores y se midió el tiempo de ejecución en cada uno de 3 - 4 ms. En la tabla 3, se muestran los resultados promediados para los vectores F_c , F_e , F_g , con componentes de diferentes espacios de color. En la tabla 4, se muestran los datos promediados de los resultados del algoritmo de clasificación de los vectores F_v , F_d y F_f con características pertenecientes a componentes del mismo espacio de color. La Fig. 6 muestra uno de los resultados del algoritmo de clasificación con ambos clasificadores realizadas con el vector de características F_c .

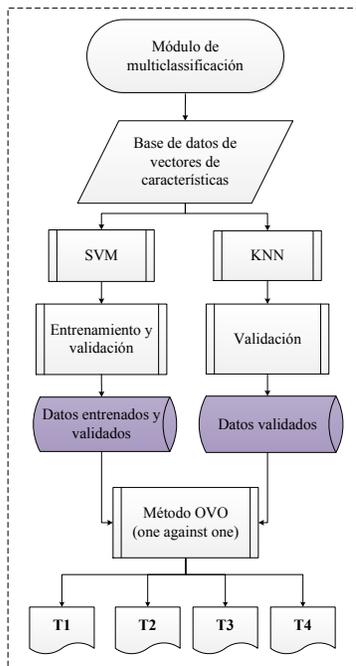


Fig. 5. Descripción del algoritmo para la clasificación.

Tabla 3. Resultados del algoritmo de clasificación para el diagnóstico de la CP en hojas de *C. pepo* L. con los vectores F_c , F_e y F_g con componentes de diferentes espacios de color.

KNN	T_1	T_2	T_3	T_4	Total	ACC%
T_1	135	1	14	4	154	87.66
T_2	2	3	2	7	14	21.43
T_3	4	0	30	5	39	76.92
T_4	5	2	0	18	25	72.00
Total	146	6	46	34	232	
ACC%	92.47	50	65.22	52.94		80.17

SVM	T_1	T_2	T_3	T_4	Total	ACC%
T_1	158	1	2	2	163	96.93
T_2	3	16	1	0	20	80.00
T_3	2	2	18	0	22	81.82
T_4	2	0	1	21	24	87.50
Total	165	19	22	23	229	
ACC%	95.76	84.21	81.82	91.30		93.01

Tabla 4. Resultados del algoritmo de clasificación para el diagnóstico de la CP en hojas de *C. pepo* L. con los vectores F_v , F_d y F_f con componentes del mismo espacio de color.

KNN	T_1	T_2	T_3	T_4	Total	ACC%
T_1	41	2	12	5	60	68.33
T_2	3	5	2	8	18	27.78
T_3	4	0	34	0	38	89.47
T_4	6	1	0	21	28	75.00
Total	54	8	48	34	144	
ACC%	75.93	62.50	70.83	61.76		70.14

SVM	T_1	T_2	T_3	T_4	Total	ACC%
T_1	199	3	2	3	207	96.14
T_2	6	20	2	0	28	71.43
T_3	7	1	8	0	16	50.00
T_4	7	0	2	17	26	65.38
Total	219	24	14	20	277	
ACC%	90.87	83.33	57.14	85.00		88.09

5. RESULTADOS

Una matriz de confusión (MC) permite obtener el desempeño del algoritmo de clasificación en términos de la proporción del número total de predicciones

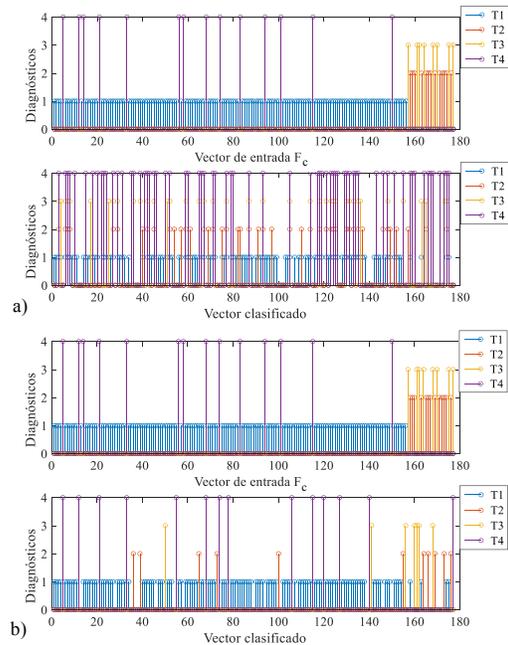


Fig. 6. Resultado del algoritmo de clasificación con el vector de características F_c : a) vector clasificado con KNN, b) vector clasificado con SVM.

correctas, verdaderos-positivos (TP) casos positivos correctamente identificados, falsos-positivos (FP) casos negativos clasificados incorrectamente como positivos, verdaderos-negativos (TN) casos negativos clasificados correctamente, falsos-negativos (FN) casos positivos incorrectamente clasificados (Salla et al. (2018)). El coeficiente $kappa$ de Cohen se utiliza como la medida estadística del acuerdo inter-evaluador para los cuatro diagnósticos (Vieira et al. (2010)). Los parámetros a medir son: exactitud (ACC , ecuación 1), sensibilidad (SN , ecuación 2), especificidad (SP , ecuación 3), tasa de falsos positivos (FPR , ecuación 4), puntaje F_β (F_β , ecuación 5) y coeficiente Cohen's $kappa$ ($kappa$, ecuación 6).

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} \quad (1)$$

$$SN = \frac{TP}{TP + FN} = \frac{TP}{P} \quad (2)$$

$$SP = \frac{TN}{TN + FP} = \frac{TN}{N} \quad (3)$$

dónde P es el número total de positivos y N es el número total de negativos.

$$FPR = \frac{FP}{TN + FP} = 1 - SP \quad (4)$$

$$F_\beta = \frac{(1 + \beta^2)(PREC * SN)}{\beta^2 * PREC + SN} \quad (5)$$

dónde β es comúnmente 0.5, 1 y 2. Para este caso, $\beta = 1$.

$$kappa = \frac{(d - q)}{(n - q)} \quad (6)$$

dónde d es la suma de datos correctamente clasificados, q es la suma de cada línea y columna en toda la matriz de confusión para ser dividida por el número total de muestras n .

A continuación, las tablas 5 y 6 presentan la evaluación final de todos los resultados con ambos clasificadores. Es observable que la salida de SVM presenta los resultados más óptimos.

Tabla 5. Resultado de la evaluación de desempeño del algoritmo de clasificación con KNN y SVM para los vectores, con características de componentes de diferentes espacios de color.

Vector	ACC%	SN%	SP%	FPR%	F_β	kappa
KNN- F_c	81.73	50.00	92.31	7.69	57.78	0.17
KNN- F_g	80.77	42.31	93.59	6.41	52.38	0.69
SVM- F_c	93.18	72.73	98.75	2.53	84.21	0.97
SVM- F_e	93.27	84.62	96.15	3.85	86.27	0.6

Tabla 6. Resultado de la evaluación de desempeño del algoritmo de clasificación con KNN y SVM para los vectores con características de componentes del mismo espacio de color.

Vector	ACC%	SN%	SP%	FPR%	F_β	kappa
KNN- F_d	77.38	38.46	91.03	8.97	46.51	0.02
KNN- F_f	77.88	26.92	94.87	5.13	37.84	-0.16
SVM- F_v	92.31	80.77	96.15	3.85	84.00	0.51
SVM- F_f	97.12	92.31	98.72	1.28	94.12	0.83

6. DISCUSIÓN

A través del procesamiento de imágenes y pruebas estadísticas se obtuvieron vectores de características para identificar el nivel de daño en las hojas de cucurbitáceas. Las imágenes describen los cambios visibles de color en las hojas cuando los síntomas están presentes. Lo descriptores de textura resultaron útiles para el análisis de enfermedades en hojas de plantas. Con pruebas estadísticas como la prueba de Lilliefors, el ANOVA y la prueba de Tukey, se observó la variabilidad de los datos y las diferencias significativas entre niveles de daño (Herrmann et al. (2017)). El algoritmo para la extracción y selección de características definieron la entrada de datos principal la clasificación. Los mejores resultados se obtuvieron con el clasificador SVM debido al comportamiento no lineal de los datos. Entre los resultados importantes de las pruebas se obtuvieron los valores óptimos para el vector F_e con un $ACC = 93.27\%$ y $kappa = 0.6$, considerando los CC de los espacios RGB y YCbCr con las características *Entro*, *Homom*, *Idmnc*, *Dvarh*, *Contr*. Para el caso de los vectores de características de CC del mismo espacio de color, el vector F_f obtuvo un $ACC = 97.12\%$ y $kappa = 0.83$, con los CC del espacio de color L^*a^*b con las características *Dissi*, *Savgh*, *Idmnc*, *Contr*, *Dvarh*, *Energ*.

7. CONCLUSIONES

En este trabajo, se presenta la extracción de características de imágenes para el diagnóstico de una enfermedad fúngica en las cucurbitáceas. La detección automática y la clasificación, se proponen con una metodología en base a pruebas estadísticas y clasificadores binarios a través de imágenes para

identificar los niveles de daño causados por la cenicienta en hojas de plantas de Cucurbita pepo L. Doscientos ochenta y seis descriptores de textura fueron calculados sobre muestras de imágenes de hojas, de los cuales, resultaron 53 características óptimas para la detección y clasificación de los cuatro niveles de daño propuestos. Se realizó una serie de pruebas, de las cuales los resultados fueron óptimos y con mejor desempeño al utilizar los clasificadores SVM. Entre las ventajas, se ofrece bajo costo computacional, proceso no destructivo de la planta y la implementación en otras cucurbitáceas con características similares. Este trabajo comprueba, que combinando el procesamiento de imágenes con esta metodología, es posible tener una herramienta no destructiva para soluciones en la agricultura.

REFERENCIAS

- Barbedo, J.G.A. (2014). Using digital image processing for counting whiteflies on soybean leaves. *Journal of Asia-Pacific Entomology*, 17(4), 685 – 694.
- Brynnolfsson, P., Nilsson, D., Torheim, T., Asklund, T., Karlsson, C., Trygg, J., Nyholm, T., and Garpebring, A. (2017). Haralick texture features from apparent diffusion coefficient (adr) mri images depend on imaging and preprocessing parameters. *Scientific Reports*, 7, 1 – 11. doi:https://doi.org/10.1038/s41598-017-04151-4.
- Haralick, R.M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621.
- Herrmann, I., Berenstein, M., Paz-Kagan, T., Sade, A., and Karnieli, A. (2017). Spectral assessment of two-spotted spider mite damage levels in the leaves of greenhouse-grown pepper and bean. *Biosystems Engineering*, 157, 72 – 85.
- Mattonen, S.A., Huang, K., Ward, A., Senan, S., and Palma, D.A. (2014). New techniques for assessing response after hypofractionated radiotherapy for lung cancer. *Journal of Thoracic Disease*, 6(4), 375–386.
- Moldagulova, A. and Sulaiman, R.B. (2017). Using knn algorithm for classification of textual documents. In *2017 8th International Conference on Information Technology (ICIT)*, 665–671.
- Pydipati, R., Burks, T., and Lee, W. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, 52(1), 49 – 59.
- Rossi, F. and Mirtchev, V. (2016). Chapter 4 - analysis of variance (anova). In F. Rossi, and V. Mirtchev (eds.), *Statistics for Food Scientists*, 19 – 29. Academic Press, San Diego.
- Rumpf, T., Mahlein, A.K., Steiner, U., Oerke, E.C., Dehne, H.W., and 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.
- Salla, R., Wilhelmiina, H., Sari, K., Mikaela, M., Pekka, M., and Jaakko, M. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural Processes*, –.
- Vieira, S.M., Kaymak, U., and Sousa, J.M.C. (2010). Cohen's kappa coefficient as a performance measure for feature selection. In *International Conference on Fuzzy Systems*, 1–8.
- Yuan, L., Zhang, J., Zhao, J., Du, S., Huang, W., and Wang, J. (2012). Discrimination of yellow rust and powdery mildew in wheat at leaf level using spectral signatures. In *2012 First International Conference on Agro- Geoinformatics (Agro-Geoinformatics)*, 1–5. doi:10.1109/Agro-Geoinformatics.2012.6311599.