

Clasificación de granos de polen: Efecto de la distancia inter-pixel en GLCM

Leyra Martínez, Pedro Arguijo, Antonio Hiram Vázquez López,
Roberto Ángel Meléndez Armenta

Tecnológico Nacional de México,
Instituto Tecnológico Superior de Misantla,
México

leyramartinez.lm@gmail.com, pedro_arguijo@excite.com,
{jahvazquez, ramelendez}@misantla.tecnm.mx

Resumen. La distancia juega un papel importante en la extracción de características de textura, ya que permite identificar los detalles finos y rugosos del objeto bajo prueba. En este trabajo se estudia el efecto, en la clasificación, de la distancia inter-pixel en las características de textura de segundo orden a partir de las matrices de coocurrencia a nivel de gris (GLCM, por sus siglas en inglés) de imágenes de polen. Las distancias consideradas fueron de 1 a 5 píxeles de distancia. Las características se obtuvieron a partir de imágenes de granos de polen considerando su tabla de verdad asociada, en el espacio de color CIELab. Los resultados sugieren que el comportamiento de la Red Neuronal Artificial (RNA) funciona para analizar la textura con detalles finos, puesto que a menor distancia se obtuvo una mayor exactitud, mientras que los RF funcionan para analizar tanto los detalles finos como los detalles rugosos.

Palabras clave: Polen, textura, distancia inter-pixel, matriz de coocurrencia, CIELab, RGB.

Pollen Grain Classification: Effect of Inter-Pixel Distance on GLCM

Abstract. Distance plays an important role in the extraction of texture characteristics, since it allows to identify the fine and rough details of the object under test. This work studies the effect, in the classification, of the inter-pixel distance on the second order texture characteristics from the gray level co-occurrence matrices (GLCM) of pollen images. The distances you consider were 1 to 5 pixels away. The characteristics were obtained from images of pollen grains considering their associated truth table, in the CIELab color space. The results suggest that the behavior of the Artificial Neural Network (RNA) works to analyze the texture with fine details, since at a shorter distance a higher accuracy was obtained, while RF works to analyze both fine details and rough details.

Keywords: Pollen, texture, inter-pixel distance, co-occurrence matrix, CIELab, RGB.

1. Introducción

El objetivo principal de la clasificación de los granos de polen se enfoca en determinar la especie y la familia de las plantas a la cual corresponde. Para diferenciar las especies, un palinólogo entrenado realiza la clasificación de manera manual utilizando un microscopio, midiendo atributos visuales como forma, textura y ornamentación. Sin embargo, para poder hacer un análisis completo a partir de las características observadas, se requiere una gran cantidad de tiempo. A fin de lograr un reconocimiento y conteo rápido y preciso del polen, se han propuesto diversos enfoques de automatización, los cuales proporcionan un mejor resultado, mayor rapidez y objetividad que la identificación manual de polen no puede [1].

Desde que Flenley sugirió la utilización de algoritmos para clasificar y reconocer el polen, se han propuesto diversos algoritmos de extracción y reconocimiento de características para las imágenes de polen. Algunos estudios se han centrado en el análisis de la textura superficial del grano de polen con imágenes de microscopio electrónico de barrido (SEM) [2]. Aunque el sistema reporta una exactitud del 94% para seis taxones de polen distintos no es completamente automático, ya que requiere la preparación de una muestra completa para el análisis SEM. También se ha realizado la clasificación del polen en la miel considerando la textura de las imágenes del polen [3]. Las características de 10 especies diferentes de granos polen se calcularon a partir de matrices de coocurrencia y como clasificador redes neuronales, obteniendo una exactitud del 88%. Así mismo, se han implementado sistemas de clasificación de polen basados en aprendizaje profundo [4]. Aunque su tasa de clasificación fue del 94% en la identificación de 30 tipos de polen se debe considerar que el sistema requiere grandes conjuntos de imágenes para su entrenamiento.

En este trabajo se realiza la clasificación de imágenes de polen, nuestro enfoque se basa en la extracción de características de textura de segundo orden a partir de la matriz de coocurrencia a nivel de gris (GLCM) a escalas múltiples, consideramos cinco distancias inter-píxel [5,6] en el espacio de color CIELab. Evaluamos el desempeño individual de los conjuntos de características obtenidos con redes neuronales (RNA) y bosques aleatorios (RF). Esto con la finalidad de determinar el efecto de los detalles finos y rugosos en la clasificación. En la siguiente sección abordamos la extracción de las características de textura a partir de las matrices de coocurrencia, RNA y RF. En la sección tres se explica la metodología utilizada en este trabajo. Los resultados y las conclusiones se abordan en las secciones cuatro y cinco, respectivamente.

2. Marco teórico

2.1. Matriz de coocurrencia de niveles de gris (GLCM)

La textura, aunque carece de una definición formal, es un patrón visual que contiene información importante sobre la estructura de los objetos y su relación con el entorno circundante en términos de color, forma, tamaño, etc. El análisis de la textura como

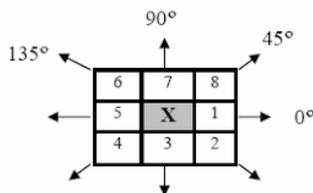


Fig. 1. Dirección de desplazamiento y rotación que definen las relaciones espaciales de los píxeles para la obtención de la matriz de coocurrencia. (Tomada de [8]).

atributo representativo visual se ha estudiado extensivamente en reconocimiento de patrones y visión por computadora, y entre alguna de sus aplicaciones se encuentra la segmentación y clasificación de imágenes, por mencionar algunas. En las imágenes digitales la textura se identifica por la disposición espacial de los píxeles con los niveles de gris. Aunque existen diferentes enfoques para extraer características de textura [7-9], en este trabajo se consideraron las que se obtienen a través de las matrices de coocurrencia (GLCM, por sus siglas en inglés).

La matriz de coocurrencia de una imagen da la probabilidad conjunta de segundo orden, $P_d(i, j)$ de los valores de intensidad de dos píxeles (i y j), separados de una distancia d a lo largo de una dirección dada θ ; reflejando la textura y las disposiciones espaciales de las intensidades de los píxeles presentes en la región de interés (ROI). Esta probabilidad conjunta; o sea la probabilidad de que i y j tengan la misma intensidad, toma la forma de una matriz cuadrada P_d , cuyo tamaño depende del número de niveles de gris discretos (intensidades) en la imagen que se está examinando [10]. Si una imagen de intensidad fuera completamente plana (es decir, no contuviera ninguna textura), la GLCM resultante sería completamente diagonal.

A medida que la textura de la imagen aumenta (es decir, a medida que las variaciones de intensidad de los píxeles locales aumentan), los valores fuera de la diagonal en el GLCM se hacen más grandes. En la fig. 1 se muestran las cuatro direcciones (0° , 45° , 90° y 135°) que se consideran para extraer la GLCM. Es importante señalar que GLCM proporciona una textura fina en distancias y recorridos cortos, y una textura gruesa en distancias y recorridos más largos [11]. El tipo de textura está relacionada con la frecuencia espacial, la textura fina con alta frecuencia espacial, mientras que la textura gruesa con una baja frecuencia espacial.

Haralick [10] propuso extraer 14 valores estadísticos de GLCM para describir las características de la textura de la imagen. En este trabajo solamente consideramos once características, las cuales se describen en la tabla 1, donde $C_{i,j}$ es la probabilidad en la celda i,j , i es el número de filas y j el número de columnas.

2.2. Clasificadores

2.2.1. Redes neuronales artificiales (RNA)

Una red neuronal artificial es un sistema de procesamiento de información que funciona de manera similar a las redes neuronales biológicas [13]. La base de estos modelos son los siguientes supuestos:

Tabla 1. Descripción de las características utilizadas.

Característica	Ecuación	Numero
Contraste	$C_1 = \sum_{i,j} (i - j)^2 \cdot C_{ij}.$	(1)
Energía	$C_2 = \sum_{i,j} C_{i,j}^2.$	(2)
Entropía	$C_3 = \sum_{i,j} -C_{i,j} \cdot \log[C_{i,j}].$	(3)
Homogeneidad	$C_4 = \sum_{i,j} \frac{C_{i,j}}{1 + (i - j)^2}.$	(4)
Correlación	$C_5 = \sum_{i,j} C_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right].$	(5)
Varianza	$C_6 = \sum_{i,j} (i - \mu)^2 C_{(i,j)}.$	(6)
Suma de promedio	$C_7 = \sum_{i=2}^{2Ng} i C_{x+y}(i).$	(7)
Suma de varianza	$C_8 = \sum_{i=2}^{2Ng} (i - f42)^2 C_{x+y}(i).$	(8)
Suma de entropía	$C_9 = - \sum_{i=2}^{2Ng} C_{x+y}(i) \log[C_{(x+y)}(i)].$	(9)
Diferencia de varianza	$C_{10} = \sum_{i=2}^{2Ng} i^2 C_{x-y}(i).$	(10)
Diferencia de entropía	$C_{11} = - \sum_{i=2}^{2Ng} C_{x-y}(i) \log[C_{(x-y)}(i)].$	(11)

- El procesamiento de la información se produce en un gran número de elementos simples llamadas neuronas.
- Las señales se transmiten entre las neuronas a lo largo de los enlaces de conexión.
- A cada enlace de conexión se le asigna un peso que multiplica la señal transmitida.

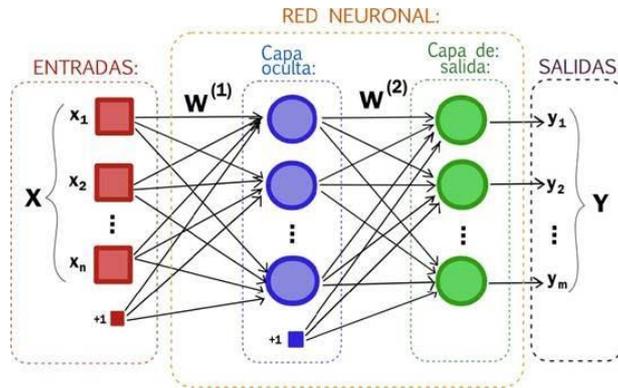


Fig. 2. Arquitectura de una red neuronal.

- Cada neurona aplica una función de activación en su entrada de red (que es la suma de las señales de entrada ponderadas) para obtener su señal de salida.

Existen dos estructuras en el desarrollo de las redes neuronales, redes de una sola capa y redes multicapa. En la fig. 2 se muestra un ejemplo de una red neuronal, en la cual se indican las interconexiones de la red, así como los pesos entre estas.

2.3.2. Random Forest (RF)

También conocidos como *Bosque Aleatorio* es una combinación de árboles predictores, tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos. En otras palabras, este clasificador crea un conjunto de árboles de decisión a partir de un subconjunto de características de entrenamiento seleccionado al azar. Luego agrega los votos de diferentes árboles de decisión para decidir la clase final del objeto de prueba [14,15].

Cada árbol individual en el bosque aleatorio da como resultado una predicción de clase y la clase con más votos se convierte en la predicción del modelo (ver fig. 3).

3. Materiales y métodos

3.1. Dataset

El dataset empleado en este documento consta de 390 imágenes de polen divididas en 12 clases diferentes, de las cuales se tienen 618 instancias debido a que algunas imágenes presentan más de un grano de polen [16].

En la fig. 4 se muestra una imagen representativa de cada una de las clases de polen que se analizan. Las clases que tiene el dataset, con su respectivo nombre palinológico y el número de imágenes por clase se muestran en la tabla 2. Tello Mijares y Flores indican el procedimiento utilizado para la obtención de las imágenes que conforman el dataset [16].

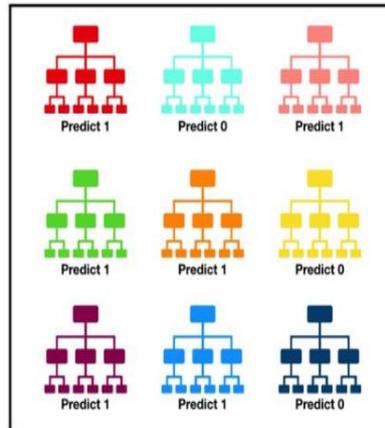


Fig.3. Visualización de un modelo de bosque aleatorio haciendo una predicción.

Tabla 2. Clasificación palinológica del conjunto de imágenes de polen.

<i>Clase</i>	<i>Nombre polen</i>	<i>Imágenes por clase</i>
1	Huisache	45
2	Alfalfa	29
3	Ortiga	31
4	Pasto	34
5	Hierba	34
6	Morera	24
7	Pacana	31
8	Oliva	28
9	Mesquite	50
10	Sauce	30
11	Pimienta	23
12	Sorgo de Alepo	31

En la fig. 5 se muestra la metodología utilizada en el desarrollo de este trabajo. Como se puede apreciar se inicia con la extracción individual del grano de polen considerando la tabla de verdad asociada. A estas imágenes se les realizó una conversión de RGB a CIELab, con lo cual se llegó a un total de 1170 imágenes; 390 por cada canal.

A cada una de las imágenes se le extrajeron las características de textura mencionadas en la sección 2.1 considerando distancias de 1 a 5 píxeles, lo cual da un total de cinco distintos dataset; uno por cada distancia.

Para el cálculo de las GLCM no se realizó cuantización de los niveles de gris, esto a pesar de la carga computacional que representa al considerar las cuatro orientaciones. Como paso final se realizó la clasificación de los dataset con RNA y RF. Cabe señalar que en la clasificación se consideraron 2 proporciones de entrenamiento y prueba 50/50 y 70/3, estas proporciones se consideraron en cada uno de los dataset.

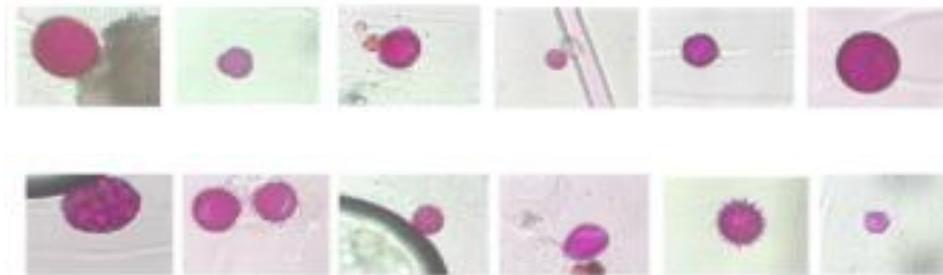


Fig. 4. Granos de polen por clases del 1- 12 y se representan así: 1-Huizache, 2-Alfalfa,3-Ortiga, 4-Pasto, 5-Hierba, 6-Morera, 7-Pacana, 8-Oliva, 9-Mesquite, 10-Sauce, 11-Pimienta, 12-Sorgo.

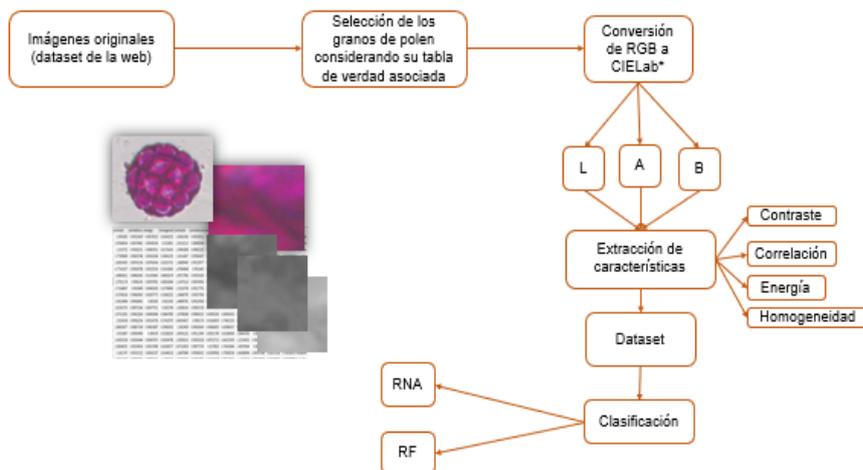


Fig. 5. Metodología grafica implementada en el desarrollo de este trabajo.

4. Resultado

El equipo en que se implementó la metodología descrita anteriormente es una laptop HP con procesador i3, 8 GB de RAM y sistema operativo a 64 bits. Para extraer el grano de polen, así como la conversión de RGB a CIELab y la extracción de características de las GLCM se utilizó MatLab 2016.

Mientras que para la clasificación se aprovechó R con su interfaz gráfica Rstudio. Para analizar el efecto de la distancia inter-pixel en la clasificación consideramos las proporciones 50/50 y 70/30 para el entrenamiento y las pruebas de cada dataset.

Como se buscó maximizar la precisión en la clasificación consideramos diferentes topologías en las redes neuronales [17] con la función arctan como función de activación, aunque se fijó a dos el número de capas ocultas. Mientras que para RF se utilizaron 200 árboles para la clasificación en todos los dataset.

Tabla 3. Resultado de clasificación por distancia para la proporción 50/50.

50/50			
Desplazamiento	RNA	Número de neuronas por capa	RF
1	90.29%	39,39	90.93%
2	90.29%	42,42	88.67%
3	88.02%	42,42	90.61%
4	87.05%	45,45	89.64%
5	89.32%	45,45	90.29%

Tabla 4. Resultado de clasificación por distancia para la proporción 70/30.

70/30			
Desplazamiento	RNA	Número de neuronas por capa	RF
1	93.51%	39,39	92.43%
2	88.64%	42,42	91.89%
3	88.10%	42,42	90.81%
4	88.10%	45,45	92.97%
5	92.43%	45,45	90.81%

En la tabla 3 se muestran los resultados de la clasificación al considerar la proporción 50/50, en la primera columna se indica la distancia inter-pixel considerada. En segunda de indica la precisión alcanzada por la red neuronal, seguida por la topología utilizada y en la cuarta columna se muestra la precisión de RF. Como se puede observar para la red neuronal los mejores resultados se obtienen para las distancias inter-pixel de 1 y 2, al haber llegado a un 90.29% en ambos casos, sin embargo, cambia el número de neuronas por capa oculta. RF alcanzó exactitudes del 90.93%, 90.61% y 90.29% para las distancias de 1, 3 y 5.

En la tabla 4 se muestran los resultados de la clasificación tomando una proporción 70/30, en la primera columna se indica la distancia inter-pixel considerada. Se puede observar que la exactitud va del 88 al 94% para la RNA y del 90 al 93% para RF. En este caso la mayor exactitud para la RNA se obtuvo con la distancia 1, alcanzando el 93.51%, con una topología de red de 2 capas ocultas con 39 neuronas cada una, mientras que para RF la mayor exactitud fue del 92.97% con distancia de 1 y del 92.97% con distancia de 4.

5. Conclusión

En este trabajo se consideraron distancias de 1 a 5 pixeles de separación para obtener características de textura de imágenes de polen, se utilizaron dos clasificadores RNA y

RF, utilizando dos proporciones de entrenamiento y prueba, 50/50 y 70/30, así como también las distintas topologías de red por distancia y un mismo número de árboles para cada distancia. Alcanzando exactitudes que van del 87 al 94%. La RNA alcanzo una exactitud del 90.29% para distancias 1 y 2 con la proporción 50/50 y una exactitud del 93.51% para la proporción 70/30 con distancia de 1.

Mientras que RF alcanzo una exactitud del 90.93%, 90.61% y 90.29% para las distancias de 1, 3 y 5, con una proporción del 50/50 y una exactitud del 92.42% y del 92.97% en distancias de 1 y 4 con una proporción del 70/30. Concluyendo que las RNA funciona para analizar la textura con detalles finos puesto que a menor distancias estos detalles pueden tener una mayor apreciación, mientras que FR funciona para analizar tanto los detalles de textura finos como para detalles rugosos. Consideramos que estos resultados no son concluyentes y es necesario estudiar otros dataset para confirmar el efecto de las distancias en las clasificaciones. De igual manera se necesitan otros extractores de textura como LBP o alguna de sus variantes junto con GLCM.

Referencias

1. Polen: Propiedades, utilización y beneficios. <https://mejorconsalud.com/polen-propiedades-utilizacion-beneficios/> (2020)
2. Langford, M., Taylor, G.E., Flenley, J.R.: Computerized identification of pollen grains by texture analysis. *Review of Palaeobotany and Palynology*, 64(1-4), pp. 197–203 (1990)
3. Kaya, Y., Erez, M.E., Karabacak, O., Kayci, L., Fidan, M.: An automatic identification method for the comparison of plant and honey pollen based on GLCM texture features and artificial neural network. *Grana*, 52(1), pp. 71–77 (2013)
4. Daoood, A., Ribeiro, E., Bush, M.: Pollen grain recognition using deep learning. In: *Bebis, G., Boyle, R., Parvin, B., Koracin, D., Porikli, F., Skaff, S., et al., editors. Advances in Visual Computing*, 10072, Springer International Publishing, pp. 321–330 (2016)
5. Alvarado-Moreno, J.D.: Defect detection in textiles using special techniques for texture analysis. *Tecnura*, 20(47), pp. 97–106 (2016)
6. Molina-Ospina, M.F., Parra-Archila, J.C., González-Gómez, A.F.: Identificación de la enterocolitis necrosante neonatal mediante técnicas de procesamiento digital de imágenes. *Universidad Autónoma de Occidente* (2008)
7. Satpathy, A., Jiang, X., Eng, H.L.: LBP-based edge-texture features for object recognition. *IEEE Transactions on Image Processing*, 23(5), pp. 1953–1964 (2014)
8. Castrillon, W.A., Alvarez, D.A., López, A.F.: Técnicas de extracción de características en imágenes para el reconocimiento de expresiones faciales. *Scientia et Technica*, 14(38), pp. 7–12 (2008)
9. Claro, M., Santos, L., Silva, W., Araújo, F., Moura, N., Macedo, A.: Automatic glaucoma detection based on optic disc segmentation and texture feature extraction. *CLEI Electronic Journal*, 19(2), pp.5 (2016)
10. Presutti, M.: La matriz de co-ocurrencia en la clasificación multiespectral: tutorial para la enseñanza de medidas texturales en cursos de grado universitario. *Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul*, pp. 1–9 (2004)
11. Soni, N., Priya, S., Bathla, G.: Texture analysis in cerebral gliomas: a review of the literature. *AJNR Am J Neuroradiol*, 40, pp. 928–934 (2019)
12. Haralick, R.M., Shanmugan, K., Dinstein, I.: Textural features for image classification. *IEEE Transaction on System, Man and Cybernetics*, SMC3, 6, pp 610–621 (1973)
13. Matich, D.J.: *Redes neuronales: conceptos básicos y aplicaciones*. Universidad Tecnológica Nacional (2001)
14. Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R.: Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), pp. 294–300 (2006)

Leyra Martínez, Pedro Arguijo, Antonio Hiram Vázquez López, Roberto Ángel Meléndez Armenta

15. Biau, G.: Analysis of a random forests model. *Journal of Machine Learning Research*, 13, pp. 1063–1095 (2012)
16. Tello-Mijares, S., Flores, F.: A novel method for the separation of overlapping pollen species for automated detection and classification. *Computational and Mathematical Methods in Medicine*, Article ID 5689346, 12 pages (2016)
17. Martínez, L., Arguijo, P., López, A.H.V., Armenta, R.Á.M.: Configuración de red neuronal para el análisis de polen. *Research in Computing Science*, 148, pp. 91–98 (2019)