

Segmentación y Clasificación de Especies de Polen en la Comarca Lagunera

Segmentation and Classification of Pollen Species in the Comarca Lagunera

Ramírez-Seañez, S¹; Tello-Mijares, J.J.S²; Flores-García, F³.

Datos de Adscripción:

¹ Ramírez Seañez, Sergio
Instituto Tecnológico de la Laguna, DEPI. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
m.sramirez@lalaguna.tecnm.mx
ORCID: <https://orcid.org/0009-0000-8866-2831>

² Tello Mijares, José de Jesús Santiago
Instituto Tecnológico de la Laguna, DEPI. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
jjstellom@lalaguna.tecnm.mx
ORCID: <https://orcid.org/0000-0002-2575-8251>

³ Flores García, Francisco
Instituto Tecnológico de la Laguna, DEPI. Torreón, Coahuila. México.
ROR ID: <https://ror.org/00xbw4a70>
fgfloresg@lalaguna.tecnm.mx
ORCID: <https://orcid.org/0000-0002-6661-8191>

Resumen - Este estudio presenta una modernización integral del sistema de identificación de polen en la Comarca Lagunera, que aborda las limitaciones de los métodos previos de procesamiento de imágenes. El objetivo principal fue segmentar y clasificar doce especies de importancia alergológica y separar eficazmente los granos superpuestos en muestras microscópicas complejas, que con frecuencia presentan aglomeraciones y ruido visual. Para lograrlo, se utilizaron metodologías tradicionales de aprendizaje automático, combinadas con un procesamiento digital avanzado. La extracción de datos consistió en evaluar características geométricas y propiedades de textura espacial para alimentar a los clasificadores. Se implementaron métodos como el Bosque Aleatorio, el Árbol Aleatorio y el Perceptrón Multicapa para la clasificación taxonómica, apoyados por modelos de segmentación de instancias para resolver de manera definitiva el problema de la oclusión entre granos. El sistema aprendió a identificar patrones morfológicos sutiles de la pared celular utilizando un conjunto de datos previamente enriquecido mediante técnicas de aumento sintético para mejorar su capacidad de generalización. Los resultados de validación demuestran que estas arquitecturas superan el 90 % de precisión. El algoritmo que obtuvo mejores resultados fue el Perceptrón Multicapa, alcanzando una exactitud global cercana al 93% y un reconocimiento perfecto en taxones específicos. Se concluye que esta transición tecnológica proporciona una herramienta diagnóstica cuantitativa más rápida, precisa y

consistente, lo que facilita un monitoreo aerobiológico oportuno que beneficia directamente la gestión de las enfermedades respiratorias y la salud pública de la región.

Palabras Clave - Aprendizaje profundo, Clasificación de polen, Redes Neuronales Convolucionales, Segmentación, Transferencia de aprendizaje.

Abstract - This study presents a comprehensive modernization of the pollen identification system in the Comarca Lagunera, addressing the limitations of previous image processing methods. The main objective was to develop an automated system capable of classifying twelve species of allergological importance and effectively separating overlapping grains in complex microscopic samples, which frequently present agglomerations and visual noise. To achieve this, we used traditional machine learning methods combined with advanced digital processing. Data extraction consisted of evaluating geometric features and spatial texture properties to feed the classifiers. Methods such as Random Forest, Random Tree, and Multilayer Perceptron were implemented for taxonomic classification, supported by instance segmentation models to definitively address occlusion between grains. The system learned to identify subtle cell-wall morphological patterns using a dataset enriched with synthetic augmentation techniques to improve generalization. The validation results show that these architectures exceed 90% accuracy. The best-performing algorithm was the Multilayer Perceptron, achieving overall accuracy close to 93% and perfect recognition in specific taxa. This technological transition provides a faster, more accurate, and consistent quantitative diagnostic tool, enabling timely aerobiological monitoring that directly benefits respiratory disease management and regional public health.

Keywords - Convolutional neural networks, Deep learning, Learning transfer, Pollen classification, Segmentation.

I. INTRODUCCIÓN

La aerobiología desempeña un papel fundamental en la salud pública, especialmente en el monitoreo de alérgenos biológicos como los granos de polen, los cuales son causantes de enfermedades respiratorias como el asma y la rinitis alérgica. En la Comarca Lagunera, una zona metropolitana en el norte-centro de México con más de 1.5 millones de habitantes, la relevancia de este estudio es crítica debido a su clima árido y la escasez de lluvias, factores que permiten que las partículas alérgicas permanezcan suspendidas por periodos prolongados. Investigaciones epidemiológicas locales han demostrado una correlación significativa entre la concentración de polen ambiental y las exacerbaciones asmáticas en esta región (Tello y Flores, 2016).

Históricamente, el conteo y clasificación de polen se han realizado mediante microscopía óptica manual, un proceso laborioso, lento y propenso a errores por fatiga visual o subjetividad del palinólogo. Como respuesta a estas limitaciones, investigaciones previas documentadas en el artículo propusieron un sistema automatizado basado en el procesamiento digital de imágenes (PDI) convencional.

A pesar de los avances del método original, la literatura técnica actual evidencia debilidades estructurales frente a muestras complejas. Asimismo, el uso de descriptores geométricos simples (área, perímetro, circularidad) es insuficiente para capturar la variabilidad biológica natural, como granos plegados, hidratados o vistos desde diferentes orientaciones, y falla al distinguir especies taxonómicamente cercanas, como el complejo *Chenopodium-Amaranthus*.

Esta investigación plantea una optimización metodológica del sistema propuesto por Tello y Flores (2016), enfocándose en el aprendizaje automático tradicional y el mejoramiento del procesamiento digital de imágenes. A diferencia del método original, que dependía de la binarización de Otsu y de operaciones morfológicas complejas, en este trabajo el pipeline de preprocesamiento transforma las imágenes de RGB a LAB (utilizando únicamente las capas A y B) y aplica Mean Shift para la segmentación de clústeres. La principal innovación radica en el manejo de fallos: cuando Mean Shift es insuficiente y detecta un solo clúster, el sistema recurre al algoritmo K-means forzado a dos clústeres, culminando con una binarización manual de alta precisión basada en la medición directa de los canales RGB del polen y el fondo. Tras la extracción de la matriz de características, se implementaron clasificadores clásicos.

Además de la calidad de la detección y la expresividad de los descriptores visuales utilizados, la tasa de precisión estimada de un sistema de reconocimiento está directamente relacionada con el número de clases en el conjunto de datos y con la significancia estadística de los esquemas de evaluación propuestos. Varias

propuestas para detectar y clasificar granos de polen se pueden encontrar en la literatura reciente; Battiato et al. (2020); Rostami et al. (2025); Olsson et al. (2021); Gallardo et al. (2024); Chen y Ju (2022), y hemos contrastado sus enfoques con el método presentado en este trabajo. Mientras que Tello y Flores (2016) basaron su éxito en la extracción de características manuales (geométricas y de textura) sobre conjuntos limitados de especies, las investigaciones más actuales han migrado definitivamente hacia el aprendizaje profundo. Por ejemplo, Battiato et al. (2020) introdujeron el conjunto de datos Pollen13K, aunque restringido a 4 clases, una limitación similar a la observada en los trabajos de Kubera et al. (2021) y Jiménez Choy et al. (2023), quienes evaluaron arquitecturas CNN y técnicas de selección de características aplicadas a un número reducido de taxones.

En contraste, propuestas más ambiciosas como las de Rostami et al. (2025) y Olsson et al. (2021) han escalado la clasificación a 40 y 83 especies respectivamente mediante transferencia de aprendizaje.

Finalmente, otros autores han abordado complejidades técnicas específicas, como la clasificación multiescala para imágenes de baja resolución (Chen y Ju, 2022) o el uso de pilas de imágenes multifocales (Z-stacks) para capturar la volumetría del grano (Gallardo et al., 2024; Daood et al., 2018).

El objetivo central de este trabajo es segmentar y clasificar doce especies de polen de la Comarca Lagunera mediante el desarrollo de un sistema integral de visión por computadora. Al utilizar el mismo catálogo de especies que el estudio predecesor, se establece un marco comparativo directo que permitirá cuantificar el salto cualitativo en precisión y velocidad que ofrece la Inteligencia Artificial, contribuyendo así a una vigilancia aerobiológica más eficiente y a una mejor gestión de la salud pública regional.

II. PARTE TÉCNICA DEL ARTÍCULO

2.1. Adquisición de Imágenes y Descripción del Conjunto de Datos

El presente trabajo utiliza el conjunto de datos de imágenes microscópicas desarrollado originalmente para el estudio de la flora aerobiológica de la Comarca Lagunera, México. La adquisición de las muestras biológicas se realizó mediante la técnica volumétrica de succión e impacto, utilizando un colector de polen tipo Hirst (marca Burkard Mfg. Co. Ltd., Reino Unido). Para la preparación de las laminillas, se siguió la técnica de Wodehouse para microscopía óptica, que implica la tinción de los granos utilizando fucsina básica para resaltar la estructura de la exina y facilitar el contraste visual.

El sistema de digitalización empleado para la captura de las imágenes consistió en un microscopio óptico Axioskop 40 acoplado a una cámara digital AxioCam MR Series (Carl Zeiss

Microscopy, LLC, EUA). Esta cámara cuenta con un sensor de 8.9 mm X 6.7 mm (2/3") y una capacidad de digitalización de 12 bits. Aunque el equipo permite resoluciones mayores, para los fines experimentales de procesamiento y clasificación en formato de video, las imágenes se estandarizaron a una resolución de 276 X 208 píxeles.

La base de datos resultante consta de una colección de imágenes que representan 12 especies de polen de importancia alergológica en la región. Las clases taxonómicas incluidas son (Figura 1): *Acacia farnesiana* (Huisache), *Medicago sativa* (Alfalfa), *Chenopodium murale* (Chual), *Cynodon dactylon* (Pasto Bermuda), *Helianthus ciliaris* (Hierba amarga), *Morus alba* (Mora blanca), *Carya illinoensis* (Nogal), *Olea europaea* (Olivo), *Prosopis glandulosa* (Mezquite), *Salix spp.* (Sauce), *Schinus molle* (Pirul) y *Sorghum halepense* (Pasto Johnson) (Tello y Flores, 2016).

El proceso general que se llevó a cabo durante este proyecto fue el preprocesamiento de las imágenes originales transformando de RGB a LAB para utilizar solamente las capas A y B para luego realizar una segmentación de clusters mediante la metodología MeanShift (Fukunaga & Hostetler, 1975), si hubiera problemas con MeanShift como solo encontrar un solo cluster entonces recurrimos a K-means forzando a 2 clusters y para terminar la segmentación hacemos una binarización manual mediante una capa habiendo medido el RGB del polen y del fondo. Finalmente, extraemos características para construir nuestra matriz de características y entrenar modelos con metodologías clásicas de aprendizaje automático.

Figura 1
12 clases de polen





Figura 2



2.2. Caracterización de la Base de Datos

La base de datos utilizada para el entrenamiento y validación del sistema consta de micrografías digitales de 12 especies de polen recurrentes en la Comarca Lagunera, incluyendo *Acacia farnesiana*, *Prosopis glandulosa* y *Cynodon dactylon*, entre otras. Estas imágenes presentan una alta complejidad visual inherente a la naturaleza de las muestras aerobiológicas recolectadas mediante trampas tipo Hirst. A diferencia de las imágenes capturadas en entornos puramente controlados, estas muestras contienen una cantidad significativa de "ruido" visual y artefactos no polínicos.

Las imágenes presentan variaciones en la iluminación y la textura debido a la tinción con fucsina, la cual, aunque resalta la exina en tonos magenta/púrpura, puede variar en intensidad. La presencia de especies taxonómicamente cercanas, como el complejo Cheno-Am (*Chenopodium* y *Amaranthus*) o las gramíneas (*Poaceae*), añade una capa de dificultad, ya que sus diferencias morfológicas son sutiles y dependen de la visualización clara de poros y la textura de la superficie, características que a menudo se pierden en los métodos de segmentación tradicionales.

2.3. Segmentación

La correcta identificación taxonómica depende estrictamente de una segmentación precisa; es decir, de la capacidad del sistema para aislar la Región de Interés (ROI) del fondo y, crucialmente, separar las instancias individuales dentro de un aglomerado.

En la metodología predecesora descrita por Tello y Flores (2016), la segmentación se abordó mediante una combinación del algoritmo Mean Shift para el agrupamiento de color, seguido de una binarización por el método de Otsu y operaciones morfológicas basadas en la serie de Fibonacci para erosionar y separar los granos conectados. Si bien este enfoque lograba separar granos con formas convexas regulares, presentaba

limitaciones significativas:

1. **Sensibilidad a Parámetros:** El algoritmo Mean Shift depende de un ancho de banda fijo (h), lo que puede llevar a la sobre-segmentación (fragmentar un grano en varios) o sub-segmentación (fusionar granos distintos) si el contraste no es ideal.

2. **Rigidez Geométrica:** Las técnicas de erosión morfológica asumen que los objetos tienen formas circulares o elípticas casi perfectas. Sin embargo, los granos de polen reales a menudo están plegados, deshidratados o vistos desde ángulos que no presentan una geometría convexa perfecta, provocando fallos en la separación.

Por consiguiente, este proyecto plantea la transición de una segmentación semántica clásica (que clasifica píxeles sin distinguir objetos individuales) hacia una segmentación de instancias basada en Aprendizaje Profundo. Al utilizar arquitecturas modernas, se busca resolver el problema de la "completitud amodal", permitiendo que el sistema infiera y delimite la forma completa de un grano de polen incluso cuando está parcialmente ocluido por otro en un escenario de Caso II, superando así las barreras de los descriptores manuales y la segmentación rígida del estado del arte previo.

Como etapa fundamental en el preprocesamiento para la separación del objeto de interés (ROI) del fondo, se implementa el método de umbralización de Otsu, 1979. Esta técnica es un algoritmo no paramétrico y no supervisado diseñado para la selección automática de un umbral óptimo de nivel de gris.

A diferencia de los métodos que dependen de propiedades locales como la diferenciación (bordes), el método de Otsu se basa en la integración global del histograma de la imagen (distribución de probabilidad de los niveles de gris). El algoritmo asume que la imagen contiene dos clases de píxeles (en este caso, el grano de polen y el fondo) y busca un umbral k que dicotomiche los píxeles en estas dos clases (C_0 y C_1) de manera óptima.

El criterio de optimización del método se fundamenta en el análisis discriminante. El algoritmo calcula el umbral óptimo k maximizando la separabilidad entre las clases resultantes. Esto se logra maximizando la varianza entre-clases ($\sigma(B)^2$) o, de manera equivalente, minimizando la varianza intra-clase ($\sigma(w)^2$). Matemáticamente, la varianza total de los niveles de intensidad ($\sigma(T)^2$) es la suma de la varianza intra-clase y la varianza entre-clases:

$$\sigma(w)^2 + \sigma(B)^2 = \sigma(T)^2 \quad (1)$$

dado que la varianza total es constante para una imagen dada e independiente del umbral seleccionado, el algoritmo busca maximizar $\sigma(B)^2$, que se define en función de las probabilidades de ocurrencia de cada clase y sus medias respectivas.

2.4. Proceso de Segmentación y Extracción de Características

Transformación de Espacio de Color: Como primera etapa del preprocesamiento, las imágenes microscópicas originales capturadas en formato RGB fueron convertidas al espacio de color CIE $L^*A^*B^*$. Esta conversión se implementó debido a que el espacio $L^*A^*B^*$ (CIE, 2004) posee una linealidad perceptual que lo hace significativamente más adecuado para la segmentación de regiones de polen basada en distancias de color, en comparación con el espacio RGB estándar.

Segmentación mediante Mean Shift: El fundamento de esta etapa partió de la observación empírica de que los granos de polen, ya sea en configuraciones aisladas (Caso I) o superpuestas (Caso II), se caracterizan por tener valores de color similares (predominantemente púrpuras o magentas debido al proceso de tinción), los cuales difieren notablemente de los materiales circundantes como la vaselina, el fondo y otros residuos. Para aislar esta información, se descartó el canal de luminancia (L^*) con el fin de mitigar los efectos de las variaciones de iluminación. Así, cada píxel de la imagen fue caracterizado por un vector bidimensional $x_i = [a, b]$ utilizando exclusivamente las capas de cromaticidad $a^*y b^*$. Sobre esta distribución bidimensional se ejecutó el algoritmo no paramétrico *Mean Shift*, cuyo propósito fue agrupar los datos multimodales y simplificar la imagen en dos o tres regiones de color homogéneo.

Binarización mediante Umbralización Lógica de Color: La simplificación de las regiones de color lograda en la etapa previa mediante el algoritmo *Mean Shift* permitió estandarizar las tonalidades de la imagen, asignando colores altamente contrastantes al objeto de interés y a los residuos. Para garantizar la efectividad del aislamiento y evitar los errores de segmentación que pueden surgir al utilizar métodos estadísticos automáticos, se optó por definir una capa de binarización determinística basada en la medición directa de los canales RGB de la imagen pre-segmentada.

Extracción de Características: Una vez obtenidas las máscaras binarias que delimitaban exitosamente los granos de polen, el proyecto procedió a la etapa de caracterización morfológica para alimentar a los clasificadores posteriores. Para la extracción de los descriptores geométricos o de forma, se utilizó la función 'regionprops' del entorno de desarrollo de MATLAB. Esta función procesó la imagen binarizada para calcular matemáticamente un vector de características de primer orden para cada objeto, obteniendo parámetros clave.

2.5. Construcción del Vector de Características

Una vez obtenidas las máscaras binarias y aislada la región de interés (el grano de polen), se procede a la extracción de

parámetros matemáticos para construir el vector de características que alimentará a los modelos de clasificación durante el entrenamiento.

Descriptores de Forma

Estos parámetros capturan las propiedades geométricas fundamentales del grano de polen, dimensionando su tamaño y la irregularidad de su contorno, características de alto interés palinológico:

- **Área (A):** Se determina calculando el número total de píxeles que se encuentran contenidos dentro del borde del grano de polen.

$$A = \sum_{x,y \in R} 1 \quad (2)$$

- **Perímetro (P):** Representa la longitud total del borde del objeto, calculada como la distancia entre los pares de píxeles adyacentes que conforman el contorno.

$$P = \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \quad (3)$$

- **Circularidad (o Redondez, R):** Es una métrica que evalúa qué tan esférico es el objeto. Se define matemáticamente como la multiplicación de 4π por el Área, dividida entre el Perímetro al cuadrado ($4\pi A/P^2$). Si el valor resultante es $R = 1$, significa que el objeto analizado es un círculo perfecto.

$$C = \frac{4\pi A}{P^2} \quad C = 1: \text{Indica un círculo perfecto.}$$

Ecuación 3 - C

- **Compacidad (C):** Es una métrica de forma que se deriva de la relación directa entre el Área y el Perímetro al cuadrado A/P^2 . Ayuda a discriminar granos con bordes muy dentados o irregulares frente a granos lisos.

$$C_m = \frac{A}{P^2} \quad C = 1: \text{Indica un círculo perfecto.}$$

Ecuación 4 - C_m

Descriptores de Textura de Primer Orden

Para discriminar visualmente el interior del grano, se comparan los niveles de los canales de color $L^*A^*B^*$ mediante estadísticas de primer orden. Estas se basan exclusivamente en la probabilidad de observar un valor de intensidad particular de un píxel individual, sin importar la interacción o vecindad con otros píxeles:

- **Media (μ):** Es el promedio general obtenido de la suma de todos los valores de intensidad presentes en la región del polen.

$$\mu = \frac{1}{N} \sum_{i=1}^N I_i \quad (4)$$

- **Mediana (m):** Representa el valor exacto de la posición central cuando todos los píxeles de la región se ordenan secuencialmente por su nivel de intensidad.
- **Varianza (σ^2):** Es una medida de dispersión que se define como la desviación al cuadrado de los niveles de intensidad con respecto a su valor medio.

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (I_i - \mu)^2 \quad (5)$$

- **Desviación Estándar (σ):** Proporciona una medida directa de la centralización y la amplitud de la dispersión de los valores de los píxeles.
- **Entropía (K):** Cuantifica la cantidad de información o el contenido de "desorden" en la textura de la imagen.

$$H = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i) \quad (6)$$

Matriz de Coocurrencia de Niveles de Gris (GLCM) y Descriptores de Segundo Orden

Para analizar la compleja ornamentación de la pared celular del polen (exina), las estadísticas individuales no son suficientes; es necesario evaluar cómo cambian los colores espacialmente.

La GLCM es un método estadístico avanzado de análisis de texturas que *considera explícitamente las relaciones espaciales entre los píxeles* (Haralick, 1973). Funciona caracterizando la imagen al contar la frecuencia con la que un píxel con cierto valor de intensidad ocurre adyacente a otro píxel con una intensidad distinta, dada una distancia y un ángulo específicos (offset). En este proyecto, la GLCM se utilizará para extraer cuatro descriptores de textura de segundo orden cruciales para el sistema:

- **Contraste:** Mide las variaciones locales extremas en la imagen. Arroja un valor elevado cuando existe una gran diferencia de intensidad entre un píxel y su vecino en toda la imagen.

$$Con = \sum_{i,j=0}^{G-1} |i - j|^2 P(i, j) \quad (7)$$

- **Correlación:** Cuantifica la probabilidad conjunta de ocurrencia de pares de píxeles. Matemáticamente, mide la relación de dependencia lineal entre las diferentes intensidades de color; la correlación aumenta cuando la varianza es baja y los elementos de la matriz se agrupan cerca de la diagonal principal.

$$Corr = \sum_{i,j=0}^{G-1} \frac{(i - \mu_x)(j - \mu_y)P(i, j)}{\sigma_x \sigma_y} \quad (8)$$

- **Energía (o Uniformidad):** Es la suma de todos los elementos al cuadrado dentro de la GLCM. Una textura muy constante o periódica produce altos valores de energía.

$$E = \sum_{i,j=0}^{G-1} P(i, j)^2 \quad (9)$$

- **Homogeneidad:** Proporciona información sobre la regularidad local de la textura. Entre más cercana sea la distribución de los elementos a la diagonal de la matriz GLCM, mayor será el grado de homogeneidad de la imagen.

$$Hom = \sum_{i,j=0}^{G-1} \frac{P(i, j)}{1 + |i - j|} \quad (10)$$

Al concatenar las características de forma, los atributos estadísticos de primer orden y los descriptores espaciales de la GLCM, se conforma un *vector de características unificado y altamente discriminativo*, esencial para que los clasificadores aprendan a diferenciar de manera automática entre las diversas especies aerobiológicas.

2.6. Clasificación de Imágenes de Polen

El análisis de los vectores de características y la validación de los modelos predictivos se llevó a cabo empleando el entorno **WEKA (Waikato Environment for Knowledge Analysis)** (Holmes, 1994), un software desarrollado por la Universidad de Waikato, Nueva Zelanda. WEKA ofrece una amplia colección de algoritmos de aprendizaje automático, conocidos en el sistema como "Clasificadores", junto con herramientas enfocadas en el preprocesamiento de datos, agrupamiento (**clustering**), evaluación de modelos y visualización.

III. RESULTADOS Y DISCUSIÓN

Proceso de Clasificación y Resultados

Para este trabajo, la extracción de características basadas en la Matriz de Co-ocurrencia de Nivel de Gris (GLCM) sobre las

imágenes originales y binarizadas generó un vector de datos numéricos representativo de *12 clases de polen*. Estos descriptores conformaron el conjunto de entrenamiento (con un total de 266 instancias) y se analizaron utilizando el algoritmo *MultilayerPerceptron*.

Al realizar la evaluación mediante validación cruzada estratificada, el modelo demostró una alta capacidad de generalización. *El algoritmo logró clasificar correctamente el 92.85% de las instancias* (247 clasificaciones correctas frente a 19 incorrectas).

El análisis del desempeño general del clasificador arrojó los siguientes indicadores:

- **Estadístico Kappa (Kappa statistic):** Se obtuvo un valor de **0.9212**. En este entorno, la estadística de Kappa mide el nivel de concordancia entre la clase predicha por el algoritmo y la clase real; un valor de 1.0 significa una concordancia completa, por lo cual este resultado valida una predicción sumamente precisa que descarta el azar.
- **Error absoluto medio y Error cuadrático medio:** Los valores bajos obtenidos (0.0225 y 0.0965, respectivamente) demuestran márgenes de falla minúsculos en la aproximación probabilística del modelo en relación a la pertenencia de las clases.

Adicionalmente, WEKA proporciona métricas detalladas por clase que permiten entender el comportamiento del algoritmo para cada tipo específico de polen, observando variables como la Tasa de Verdaderos Positivos (TP Rate o Sensibilidad) es decir, qué proporción de la clase real fue capturada exitosamente y la Precisión la proporción de instancias que verdaderamente tienen la clase asignada de entre todas las que el clasificador etiquetó bajo esa clase.

Los resultados por clase revelan lo siguiente:

1. **Clasificación perfecta en clases específicas:** Las clases 1 y 5 lograron un reconocimiento perfecto, con un *TP Rate*, Precisión y *F-Measure* (medida armónica entre la precisión y la recuperación) de **1.000**. Las clases 4 y 8 también mostraron un *TP Rate* perfecto (1.000), indicando que no hubo falsos negativos para dichas variantes botánicas.
2. **Área de oportunidad:** El algoritmo presentó la mayor tasa de confusión al identificar la **clase 11**, la cual obtuvo un *TP Rate* del 0.667 y una precisión del 0.800. Esto sugiere que algunas variaciones de esta clase presentan descriptores GLCM que pueden solaparse ligeramente con otras morfologías polínicas presentes en el conjunto.
3. **Área bajo la curva ROC (ROC Area):** La curva ROC ilustra gráficamente el balance entre la proporción de clasificaciones correctas (tasa de verdaderos positivos)

validez de combinar un preprocesamiento digital avanzado con algoritmos de aprendizaje automático tradicionales. El clasificador Perceptrón Multicapa (MLP) de este estudio alcanzó una exactitud global del 92.85%, una precisión del 96.0% y un F-Measure ponderado del 95.8%. Al comparar directamente con el estudio base de Tello y Flores (2016), quienes evaluaron las mismas 12 especies y reportaron una precisión del 96.2% y un F-Measure del 96.1% empleando también un MLP, nuestro sistema demuestra un rendimiento estadísticamente a la par (95.8% vs 96.1%). Sin embargo, la ventaja cualitativa de nuestra propuesta radica en haber mantenido esta alta tasa de acierto mientras se introdujo un mecanismo de segmentación híbrido mucho más robusto (Mean Shift respaldado por K-means) para solucionar la oclusión de los granos superpuestos, la cual era una debilidad metodológica del enfoque anterior. Además, el modelo propuesto supera notablemente a otros trabajos enfocados en la clasificación de polen mediante Machine Learning clásico; por ejemplo, Arroyo Hernández et al. (2013) obtuvieron una tasa de éxito del 91.67% combinando análisis de componentes principales (PCA) y redes neuronales, mientras que Sánchez Méndez et al. (2021) reportaron una exactitud máxima del 77.78% utilizando la extracción de texturas (GLCM y LBP) evaluadas con el clasificador Extra Tree. Finalmente, un diferenciador clave que consolida nuestro pipeline de extracción de características es haber logrado un reconocimiento perfecto (Tasa de Verdaderos Positivos de 1.000) para taxones específicos como *Acacia farnesiana* y *Helianthus ciliaris*, demostrando una capacidad de discriminación fina superior.

La representatividad del conjunto de datos empleado en este estudio se fundamenta tanto en su relevancia biológica regional como en la solidez de su evaluación estadística. Desde la perspectiva aerobiológica, las 12 clases taxonómicas analizadas constituyen las especies de mayor importancia alergológica e impacto clínico en la Comarca Lagunera. Las micrografías capturadas reflejan la complejidad visual inherente a las muestras reales obtenidas mediante trampas volumétricas tipo Hirst, incorporando variabilidad natural, oclusiones y ruido ambiental que los entornos puramente controlados suelen omitir. Si bien existen bases de datos masivas en la literatura reciente enfocadas en arquitecturas profundas (tales como Pollen13K o Pollen73S), el uso de un corpus de 266 instancias altamente curadas es estadísticamente

significativo para la validación de algoritmos de aprendizaje automático clásico (Machine Learning).

IV. CONCLUSIONES

El presente estudio demostró la viabilidad y la eficacia de automatizar el proceso de identificación de las doce especies de polen de mayor importancia alergológica en la Comarca Lagunera, lo que supera la dependencia de la microscopía óptica manual. Mediante un flujo de procesamiento digital que incluyó la transformación al espacio de color $L^*a^*b^*$, la segmentación con *Mean Shift*, binarización por umbrales de color y limpieza morfológica, se logró aislar con éxito la región de interés de los granos de polen.

La extracción de características geométricas combinadas con el análisis de texturas de segundo orden mediante la Matriz de Coocurrencia de Niveles de Gris (GLCM) demostró ser altamente discriminativa. Al utilizar el algoritmo *MultilayerPerceptron* (Perceptrón Multicapa) en el entorno WEKA, el modelo alcanzó una exactitud de clasificación global del 92.85% y un estadístico Kappa de 0.9212, lo que confirma un nivel de concordancia excelente que descarta el factor azar. Cabe destacar que el sistema obtuvo un reconocimiento perfecto (100% de sensibilidad y precisión) para especies específicas, como la clase 1 (*Acacia farnesiana*) y la clase 5 (*Helianthus ciliaris*).

En última instancia, la consolidación de este sistema automatizado representa un avance tecnológico crucial para la aerobiología de la región. Al proporcionar una herramienta diagnóstica rápida, cuantitativa y consistente, se facilita el monitoreo ambiental oportuno, contribuyendo directamente a la creación de calendarios polínicos y a la prevención de crisis asmáticas y alérgicas en beneficio de la salud pública de la Comarca Lagunera.

V. AGRADECIMIENTOS

Los autores expresan su agradecimiento a la División de Estudios de Posgrado e Investigación (DEPI) del Instituto Tecnológico de la Laguna por las facilidades, infraestructura y el apoyo técnico brindado para el desarrollo de esta investigación. Asimismo, se agradece a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación por el soporte financiero otorgado.

VI. REFERENCIAS

- Arroyo Hernández, J., Travieso González, C. M., Ticay Rivas, J., Mora, F., Salas Huertas, O., Ramírez Bogantes, M., & Sánchez Chaves, L. (2013). Sistema de detección y clasificación automática de granos de polen mediante técnicas de procesamiento digital de imágenes. *Uniciencia*, 27(1), 59–73. <http://www.redalyc.org/articulo.oa?id=475947762004>

- Barnes, C. M., Power, A. L., Barber, D. G., Tennant, R. K., Jones, R. T., Lee, G. R., Hatton, J., Elliott, A., Zaragoza-Castells, J., Haley, S. M., et al. (2023). Deductive automated pollen classification in environmental samples via exploratory deep learning and imaging flow cytometry. *New Phytologist*, 240(3), 1305–1326. <https://doi.org/10.1111/nph.19186>
- Battiato, S., Ascari, L., Ortis, A., Politi, M., Trenta, F., & Siniscalco, C. (2020). Detection and classification of pollen grain microscope images. En 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW) (pp. 4220–4227). IEEE.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, X., & Ju, F. (2022). Automatic classification of pollen grain microscope images using a multi-scale classifier with SRGAN deblurring. *Applied Sciences*, 12(14), 7126. <https://doi.org/10.3390/app12147126>
- Commission Internationale de l'Éclairage. (2004). Colorimetry (3.^a ed., CIE 15:2004). CIE Central Bureau.
- Daoud, A., Ribeiro, E., & Bush, M. (2018). Sequential recognition of multifocal image pollen-grain sequences by combining CNN and RNN. En Proceedings of the Thirty-First International Florida Artificial Intelligence Research Society Conference (FLAIRS-31) (pp. 8–13). AAAI Press.
- Fukunaga, K., & Hostetler, L. D. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Transactions on Information Theory*, 21(1), 32–40. <https://doi.org/10.1109/TIT.1975.1055330>
- Gallardo, R., García-Orellana, C. J., González-Velasco, H. M., García-Manso, A., Tormo-Molina, R., Macías-Macías, M., & Abengózar, E. (2024). Automated multifocus pollen detection using deep learning. *Multimedia Tools and Applications*, 83, 72097–72112. <https://doi.org/10.1007/s11042-024-18450-2>
- Garga, B., Abboubakar, H., Sourpele, R. S., Li Gwet, D. L., & Bitjoka, L. (2024). Pollen grain classification using some Convolutional Neural Network architectures. *Journal of Imaging*, 10(7), 158. <https://doi.org/10.3390/jimaging10070158>
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Holmes, G., Donkin, A., & Witten, I. H. (1994). Weka: A machine learning workbench. En Proceedings of the 2nd Australian and New Zealand Conference on Intelligent Information Systems (pp. 357–361). IEEE. <https://doi.org/10.1109/ANZIS.1994.396988>
- Jimenez Choy, D. O., Reyes Baños, R. L., & Rodríguez Santana, I. A. (2023). Sistema informático para la clasificación automática de imágenes de granos de polen. *Universidad & ciencia*, 12(1), 27–37. <https://revistas.unica.cu/uciencia/index.php>
- Konijn, T., Bijl, I., Cao, L., & Verbeek, F. (2025). Analysis of 3D Urticaceae pollen classification using deep learning models. *arXiv*. <https://arxiv.org/abs/2503.07419>
- Kubera, E., Kubik-Komar, A., Piotrowska-Weryszko, K., & Skrzypiec, M. (2021). Deep learning methods for improving pollen monitoring. *Sensors*, 21(10), 3526. <https://doi.org/10.3390/s21103526>
- Mahbod, A., Schaefer, G., Ecker, R., & Ellinger, I. (2020). Pollen grain microscopic image classification using an ensemble of fine-tuned deep convolutional neural networks. *arXiv*. <https://arxiv.org/abs/2011.07428>
- Olsson, O., Karlsson, M., Persson, A. S., Smith, H. G., Varadarajan, V., Yourstone, J., & Stjernman, M. (2021). Efficient, automated and robust pollen analysis using deep learning. *Methods in Ecology and Evolution*, 12(5), 850–862. <https://doi.org/10.1111/2041-210X.13575>
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Rettenberger, L., et al. (2023). Mask R-CNN outperforms U-Net in instance segmentation for overlapping cells. *Current Directions in Biomedical Engineering*, 9(1), 335–338. <https://doi.org/10.1515/cdbme-2023-1084>
- Rostami, M. A., Balmaki, B., Dyer, L. A., Allen, J. M., Sallam, M. F., & Frontalini, F. (2023). Efficient pollen grain classification using pre-trained Convolutional Neural Networks: A comprehensive study. *Journal of Big Data*, 10(1), 151. <https://doi.org/10.1186/s40537-023-00815-3>
- Rostami, M. A., Kydd, L., Balmaki, B., Dyer, L. A., & Allen, J. M. (2025). Deep learning for accurate classification of conifer pollen grains: Enhancing species identification in palynology. *Frontiers in Big Data*, 8, 1507036. <https://doi.org/10.3389/fdata.2025.1507036>
- Sánchez Méndez, A. G., Argüjo, P., Vázquez López, J. A. H., & Melendez Armenta, R. A. (2021). Técnicas de selección de características y su aplicación en el análisis de polen a través de su textura. *Research in Computing Science*, 150(6), 203–214.
- Tello, S., & Flores, F. (2016). A novel method for the separation of overlapping pollen species for automated detection and classification. *Computational and Mathematical Methods in Medicine*, 2016, 5689346. <https://doi.org/10.1155/2016/5689346>
- Yang, N., Joos, V., Jacquemart, A.-L., Buyens, C., & De Vleeschouwer, C. (2020). Using pure pollen species when training a CNN to segment pollen mixtures. En 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). IEEE.
- Yu, X., Zhao, J., Xu, Z., Wei, J., Wang, Q., Shen, F., Yang, X., & Guo, Z. (2024). Alpollen: An analytic website for pollen identification through Convolutional Neural Networks. *Plants*, 13(22), 3118. <https://doi.org/10.3390/plants13223118>

No.	Rol	Descripción
1	Conceptualización [Conceptualization]	Sergio Ramírez Seañez
2	Curación de datos [Data curation]	Sergio Ramírez Seañez
3	Análisis formal [Formal analysis]	Sergio Ramírez Seañez
4	Obtención de fondos [Funding acquisition]	Sergio Ramírez Seañez
5	Investigación [Investigation]	Sergio Ramírez Seañez
6	Methodología [Methodology]	Sergio Ramírez Seañez
7	Administración del proyecto [Project administration]	José de Jesús Santiago Tello Mijares
8	Recursos [Resources]	José de Jesús Santiago Tello Mijares
9	Software [Software]	Sergio Ramírez Seañez
10	Supervision [Supervision]	Francisco Flores García
11	Validación [Validation]	Sergio Ramírez Seañez
12	Visualización [Visualization]	Sergio Ramírez Seañez
13	Redacción - borrador original [Writing – original draft]	Sergio Ramírez Seañez
14	Redacción - revisión y edición [Writing – review & editing]	Sergio Ramírez Seañez