

# Pollen Grains Classification with a Deep Learning System GPU-Trained

J.M. Ruiz-Varela, S. Ortega-Cisneros, P. Moreno-Villalobos, Jorge Rivera and Miguel Rivera-Acosta

**Abstract**— Traditional approaches to automatic classification of pollen grains consisted of classifiers working with feature extractors designed by experts, which modeled pollen grains aspects of special importance for biologists. Recently, a Deep Learning (DL) algorithm called Convolutional Neural Network (CNN) has shown a great improvement in performance in many computer vision tasks such as classification, due to this great performance the computational requirements have increased considerably; therefore, it is advisable to use new platforms such as the Graphics Processing Unit (GPU), which offer large computational resources for the development of new systems with CNN. This paper presents the GPU-Trained implementation of a DL system with the CNN algorithm, proposing a CNN model capable of running on a GPU in real-time for the automatic classification of 19 different pollen grains belonging to 14 different families, which are found in high concentrations in Mexico, and which are large interest in areas such as beekeeping, paleoecology, botany, allergology, agriculture among others. These areas seek to improve the collection of palynological data in terms of time and accuracy. In order to evaluate our model, evaluation tests were performed in the NVIDIA Jetson TX2 Developer Kit GPU. Experimental results achieves around 90% in CCR and Sensitivity in the proposed model. Additionally, the proposed model works at a processing speed of 6,826 Frames Per Second (FPS) and has approximately 50% fewer parameters than reported in related works.

**Index Terms**— Convolutional Neural Network, Deep Learning, Graphics Processing Unit, Transfer Learning.

## I. INTRODUCCION

Los datos palinológicos se dividen en dos grupos para su estudio, *polen fósil* y *polen actual*. El polen fósil brinda información muy precisa acerca del tipo de ambiente que existió en determinados yacimientos arqueológicos, también contribuye con datos para la investigación paleogeográfica, con la cual se reconstruyen las condiciones geográficas existentes

J. M. Ruiz-Varela está con el Departamento de Diseño Electrónico, en CINVESTAV Unidad Guadalajara, Jalisco 45019, México (jmrui@gd.cinvestav.mx).

S. Ortega-Cisneros está con el Departamento de Diseño Electrónico, en CINVESTAV Unidad Guadalajara, Jalisco 45019, México (sortega@gdl.cinvestav.mx).

P. Moreno-Villalobos está con el Departamento de Electrónica de Potencia, en CINVESTAV Unidad Guadalajara, Jalisco 45019, México (pmoreno@gdl.cinvestav.mx).

Jorge Rivera está con el Departamento de Diseño Electrónico, en CINVESTAV Unidad Guadalajara, Jalisco 45019, México (riveraj@gdl.cinvestav.mx).

Miguel Rivera-Acosta está con el Departamento de Diseño Electrónico, en CINVESTAV Unidad Guadalajara, Jalisco 45019, México (marivera@gdl.cinvestav.mx).

en la superficie terrestre a lo largo de ciertas eras geológicas.

Por otro lado, el polen actual contribuye con información de fenómenos como la *lluvia polínica*, comportamiento del polen durante su transporte, y establecimiento taxonómico [1].

En México los datos palinológicos son de gran importancia en áreas como apicultura [2], botánica [3], paleoecología [4], agricultura [5], alergología [6], entre otras; en dichas áreas es de gran importancia la clasificación correcta de granos de polen concentrados en el aire ya que, en el caso de la alergología, le permite al alergólogo administrar tratamientos acertados a pacientes que padecen de alergia al polen.

Las enfermedades alérgicas son un problema de salud para la sociedad actual, según la Organización Mundial de Alergias (WAO, por sus siglas en inglés, The World Allergy Organization), aproximadamente 400 millones de habitantes padece de rinitis alérgica (alergia respiratoria), con frecuencia asociada al polen [7]. Los pólenes principalmente afectan en primavera y verano, las diferentes estaciones están relacionadas con distintos tipos de alérgenos, en los que una persona alérgica puede verse más expuesta ante una proliferación repentina de ellos [8].

Uno de los retos principales de la extracción de datos palinológicos es la automatización en la clasificación, esto con gran eficiencia en velocidad y precisión. Actualmente este proceso es desarrollado de forma *manual* por personal altamente calificado (ya que es indispensable el conocimiento detallado de la morfología del polen a clasificar para evitar errores), que lo describen como un proceso agobiante y de gran exigencia de tiempo. Un proceso de clasificación de polen manual mantiene ocupada a la persona calificada un promedio de 10 horas al día, pudiendo verse afectada la precisión en la clasificación a causa del cansancio [9], [10].

Como resultado, existe un gran interés en diversas áreas para desarrollar un sistema de clasificación de granos de polen automático, para incorporarlo en la práctica diaria de recolección de datos palinológicos y sea una herramienta de apoyo de gran velocidad y precisión.

En los últimos años, se ha adoptado un novedoso algoritmo de Aprendizaje Profundo (DL, por sus siglas en inglés, Deep Learning), llamado Red Neuronal Convolutiva (CNN, por sus siglas en inglés, Convolutional Neural Network). El término DL hace referencia a que son redes muy profundas, es decir, cuentan en ocasiones con cientos de capas ocultas entre las capas de entrada y salida. Las CNN están basadas en el perceptrón multicapa; la finalidad de este algoritmo es simular la corteza visual del cerebro humano [11], [12].

Los fundamentos de las CNN fueron establecidos en [13] por Yann LeCun en 1990, presentando una red neuronal artificial multicapa llamada LeNet, la cual era capaz de clasificar dígitos escritos a mano e incorporaba el esquema de entrenamiento de

retropropagación. Sin embargo, debido a la falta de recursos computacionales en aquella época, la LeNet no pudo ser incorporada a la clasificación de tareas más ambiciosas.

En 2012, Alex Krizhevsky presenta en [14] una arquitectura de CNN llamada AlexNet, la cual muestra una mejora en la clasificación de imágenes. Debido al éxito obtenido por AlexNet, muchos trabajos han sido propuestos con la finalidad de mejorar el rendimiento de la clasificación utilizando CNN, tales como GoogLeNet [15], VGGNet [16] y ZFNet [17].

Debido a su gran desempeño, las CNN son ampliamente utilizadas en diversas tareas de visión por computadora, tales como, segmentación [18], detección [19] y clasificación [20]; esto mediante los métodos de Transferencia de Aprendizaje (TL, por sus siglas en inglés, Transfer Learning) [20] y entrenamiento Desde Cero (FS, por sus siglas en inglés, From Scratch) [14].

Como resultado, los requerimientos computacionales se incrementaron en gran medida. Los dispositivos de nueva generación como las Unidades de Procesamiento Gráfico (GPU, por sus siglas en inglés, Graphics Processing Unit) son ampliamente recomendadas para el desarrollo de sistemas complejos como las CNN [14]; ya que se componen de cientos de núcleos que forman arquitecturas masivamente paralelas, las cuales llegan a computar una gran cantidad de Operaciones en Punto Flotante por Segundo (FLOPS, por sus siglas en inglés, Floating Point Operations per Second) en el orden de los *Giga*, como es mencionado en [21].

Con el surgimiento de nuevos algoritmos como las CNN se satisfacen problemáticas de los enfoques tradicionales (dificultades de selección de características), teniendo en un mismo método y de forma automática las etapas de extracción de características y clasificación, consiguiendo así grandes niveles de representación de los datos, superando de este modo todo enfoque tradicional [12].

Los enfoques tradicionales dividen en dos etapas el problema de la clasificación de granos de polen, en su primera etapa aplican métodos discriminativos sobre conjuntos de imágenes, extrayendo características específicas (las características varían de acuerdo al descriptor, existen bancos de filtros que extraen características de forma, color, textura, etc.), en la segunda etapa se aplican métodos de clasificación a las características extraídas.

En [22] es usada la *transformada de Wavelet* para extraer características de textura de un conjunto de 210 imágenes, posteriormente se utilizan clasificadores comunes de *Aprendizaje Automático* como: *Árboles de Decisión*, Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés, Support Vector Machines) y los K Vecinos más Cercanos (K-NN, por sus siglas en inglés, K-Nearest Neighbors), para clasificar 7 tipos de granos de polen reportando una precisión de 79%, utilizando el SVM.

En [23] se presenta una implementación del método K-NN, capaz de discriminar en los granos de polen variaciones de forma y textura. La implementación es probada en 11 especies congéneres utilizando un conjunto de 1083 imágenes, alcanzando un 93.3% de precisión.

En [24] se usa un algoritmo denominado *Bosques Aleatorios* para clasificar un conjunto de imágenes de polen moderno recopilado de 211 sitios de África del Sur, dividiendo el

conjunto de imágenes por zonas, alcanzando un promedio en la clasificación de 90.14% de precisión.

Se presenta en [25] una evaluación de la técnica Bolsa de Palabras (BOW, por sus siglas en inglés, Bag of Words) con algoritmos auxiliares de extracción de características como, Transformación de Características Invariante a la Escala (SIFT, por sus siglas en inglés, Scale Invariant Feature Transform) y Aceleración Robusta de Características (SURF, por sus siglas en inglés, Speed Up Robust Feature), utilizando posteriormente algoritmos de aprendizaje supervisado como SVM, K-NN e Impulso Adaptativo (AdaBoost, por sus siglas en inglés, Adaptive Boosting); el objetivo de este trabajo es clasificar 9 diferentes tipos de granos de polen con base a un conjunto de 180 imágenes; los autores reportan una precisión máxima del 74%, utilizando un SVM.

En [26], los autores implementan distintas técnicas de extracción de características como BOW y Color, Forma y Textura (CST, por sus siglas en inglés, Color, Shape and Texture), con algoritmos de aprendizaje automático como: Árboles de Decisión, K-NN, SVM y una variante de SVM denominada C-Clasificación de Vectores de Soporte (C-SVC, por sus siglas en inglés, C-Support Vector Classification), para clasificar 23 clases de granos de polen con base a un conjunto de 805 imágenes; los resultados más favorecedores, los presenta la combinación CST+BOW+C-SVC, reportando una precisión de 64% en la clasificación.

Sin embargo, hay otra forma de abordar el problema de la clasificación de granos de polen, la cual consiste en extraer las características principales de las imágenes y clasificarlas de forma automática con grandes resultados, utilizando un sólo algoritmo, denominado CNN.

Durante los últimos años, las CNN han sido utilizadas en muchas tareas de visión por computadora, algunos trabajos han aplicado este paradigma a la clasificación de granos de polen.

En [27], se utiliza el método de TL en la CNN AlexNet para clasificar 23 tipos polínicos diferentes, considerando un conjunto de 805 imágenes, reportando una precisión de 85.1%.

En [28], los autores implementan un sistema de clasificación de granos de polen utilizando el algoritmo CNN con los métodos de TL (CNN AlexNet) y entrenamiento FS, con los cuales clasifican 30 diferentes especies de granos de polen, basándose en un conjunto de imágenes recopiladas por un Microscopio Electrónico de Barrido (SEM, por sus siglas en inglés, Scanning Electron Microscope) y por un Microscopio de Iluminación (LM, por sus siglas en inglés, Light Microscope), reportando una precisión de 89.95% con el método de TL y un 84.47% de precisión para el método de entrenamiento FS, presentando una propuesta la cual cuenta con alrededor de 20,000,000 de parámetros.

En [29], es desarrollado el método de TL en la CNN AlexNet, esto, para extraer las características más significativas de los granos de polen en las capas más profundas de la red, posteriormente, se desarrolla la clasificación mediante un Clasificador Discriminante Lineal (CDL), se clasifican 46 tipos de granos de polen reportando un 97.86% de precisión en la clasificación; el conjunto de imágenes utilizado en este trabajo fue generado con el microscopio *Classifynder* [30].

En [31], son utilizados los métodos de TL y entrenamiento FS en tres diferentes arquitecturas de CNN, presentando 88.73% de precisión en la clasificación para el método de

entrenamiento FS y 96.24% para el método de TL, estos resultados fueron obtenidos utilizando la arquitectura de CNN DenseNet-121, al clasificar 134 especies de granos de polen, y utilizando un conjunto de imágenes recopiladas por un LM.

Se presenta en [32], las implementaciones de los métodos: entrenamiento FS y TL, se desarrolla el TL en la arquitectura de CNN VGG16, son desarrolladas estas implementaciones con la finalidad de clasificar 10 tipos de granos de polen, utilizando un conjunto de imágenes multifocales denominados “z-stacks”, reportando para el método de TL un 100% de precisión en la clasificación y 95.91% para el método de entrenamiento FS, presentando una propuesta la cual cuenta con alrededor de 108,644,625 parámetros.

En [33], los autores proponen una CNN entrenada FS, con el objetivo de clasificar 11 clases de granos de polen, trabajando con un conjunto de 2,200 imágenes recopiladas por un LM; los autores reportan una precisión de 95.9%, en la clasificación.

En [34], utilizando el método de entrenamiento FS, se propone una CNN para clasificar 15 tipos polínicos diferentes, trabajando sobre un conjunto de imágenes recopilado por un LM, obteniendo un 83% de precisión en la clasificación.

Como se puede observar, en [22], [23], [25], [32] y [33], se clasifican como máximo 11 tipos de granos de polen, además, estos trabajos utilizan conjuntos de imágenes bastante reducidos [26], pero al ser pocas clases se observa un favorecimiento en la precisión de la clasificación. En [24], los autores no especifican la cantidad de granos de polen a clasificar, ni el tamaño del conjunto de imágenes, reportando una precisión promedio bastante favorable. En [23], [28], [29], [31] y [32], se utilizan conjuntos de imágenes en condiciones casi perfectas, obteniendo altos índices en las métricas de clasificación, sin embargo, en las rutinas de clasificación cotidianas no se trabaja bajo este esquema. En [23] y [28] son utilizadas imágenes recopiladas por un SEM, el cual produce imágenes de muy alta calidad (en escala de grises), que permiten extraer más características de los granos de polen, facilitando la tarea de clasificación, pero el SEM es al menos 15 veces más costoso que el LM, y por consecuencia no es comúnmente utilizado. En [29], se utilizan imágenes obtenidas por un microscopio especializado “Classifynder”, pero la incorporación de este sistema involucra una etapa extra a las rutinas de clasificación comunes, además de generar un costo adicional, en [32], es utilizado un conjunto de imágenes denominado z-stacks, sin embargo, realizar estos z-stacks, se convierte en una tarea aún más tediosa para el palinólogo, ya que requiere de aun mayor cantidad de imágenes por cada grano de polen a clasificar.

En [23] y [24], carecen de explicación del modo en que extraen y utilizan las características de las imágenes que procesan.

Por otro lado, en [27], [28] y [34] a pesar de utilizar un algoritmo y métodos bastante novedosos que han demostrado grandes resultados [14], reportan porcentajes de precisión en la clasificación poco favorables.

En [27], se utiliza un conjunto limitado de imágenes, en el cual no se hace uso de técnicas como Aumento de Datos (DA, por sus siglas en inglés, Data Augmentation), la cual es ampliamente utilizada para favorecer el rendimiento en las tareas de reconocimiento de imágenes.

Finalmente [27], [28] y [32], desarrollan las implementaciones en Unidades Centrales de Procesamiento (CPU, por sus siglas en inglés, Central Processing Unit), sin embargo, al concluir sus trabajos, sugieren el desarrollo de futuras implementaciones utilizando dispositivos GPU.

En algunos de los trabajos se presentaron resultados muy prometedores, sin embargo, deben considerarse variables que dan mayor o menor complejidad a cada uno, esas variables pueden ser, la cantidad de clases en el conjunto de imágenes (tipos diferentes de granos de polen a clasificar), similitud entre las clases, tamaño y calidad del conjunto de imágenes (cantidad de muestras por clase y buena resolución de las muestras permitirán entrenar modelos más precisos), una vez considerado esto, se puede determinar que entre mayor cantidad de clases exista en el conjunto de imágenes, y mayor parecido tengan, la clasificación resulta ser más complicada, como consecuencia la precisión del sistema disminuye.

En este trabajo se presenta una implementación en GPU del algoritmo CNN para la clasificación automática de granos de polen, que tiene como objetivo, incorporar el conocimiento de biólogos expertos en un sistema de decisión de gran velocidad y precisión. Con el desarrollo de este sistema, son modeladas propiedades de los granos de polen que son comúnmente discriminadas por biólogos. Se emplearon dos métodos diferentes basados en CNN para un mejor análisis, en el primer método se diseñan y proponen diversas arquitecturas de CNN, las cuales se entrenan FS, en el segundo método se hace uso de la técnica de TL en la CNN AlexNet; ambos métodos son entrenados con base a un conjunto de imágenes taxonómicamente amplio, el cual fue aumentado mediante la técnica de DA, las imágenes fueron obtenidas de un LM, el cual es comúnmente utilizado por biólogos en sus rutinas de clasificación de granos de polen. La principal contribución de este trabajo es la mejora en el desempeño de la clasificación, mediante el desarrollo de un sistema diseñado a medida (de acuerdo a su aplicación) el cual presenta ventajas en rendimiento con respecto a trabajos relacionados.

El trabajo está organizado de la siguiente manera: La Sección II proporciona una descripción del método propuesto para la clasificación automática de granos de polen. La Sección III explica los experimentos y se discuten los resultados que respaldan el método propuesto. La Sección IV resume las conclusiones y describe las futuras líneas de investigación.

## II. UN MÉTODO AUTOMÁTICO PARA CLASIFICAR GRANOS DE POLEN

### A. Proceso de Clasificación de Granos de Polen

A continuación, en la Fig. 1, se muestra y describe detalladamente el proceso de clasificación de granos de polen.

El primer paso en este proceso, consiste en crear y etiquetar manualmente un conjunto de imágenes de las distintas especies de granos de polen a clasificar.

El segundo paso, desarrolla la técnica de DA al conjunto de imágenes creado, obteniendo un conjunto aumentado.

El tercer paso, consiste en desarrollar un redimensionamiento, por motivos experimentales, se generó un nuevo conjunto de imágenes, a partir del original, de 96x96 píxeles.

Como cuarto paso, se desarrollan las etapas de: extracción de características y clasificación de las imágenes de entrada, utilizando una CNN.

La etapa de extracción de características, es desarrollada por Capas Convolucionales y Capas de Agrupamiento; cada imagen de entrada es procesada primeramente por una capa convolucional, la cual es la encargada de extraer y aprender los rasgos característicos de los granos de polen, esto se desarrolla al procesar la imagen con diversos *kernels* (operación de convolución), generando de esta manera mapas de características.

Se puede considerar que las capas convolucionales están formadas por neuronas que utilizan un esquema de compartimiento de parámetros por medio de conexiones locales; posteriormente los datos obtenidos de una capa convolucional son procesados por una función de activación no lineal, debido a su simplicidad es común el uso de la función Unidad Lineal Rectificada (ReLU, por sus siglas en inglés, Rectified Linear Unit), la cual supera el problema del desvanecimiento del gradiente, permitiendo que los modelos aprendan más rápido y funcionen mejor.

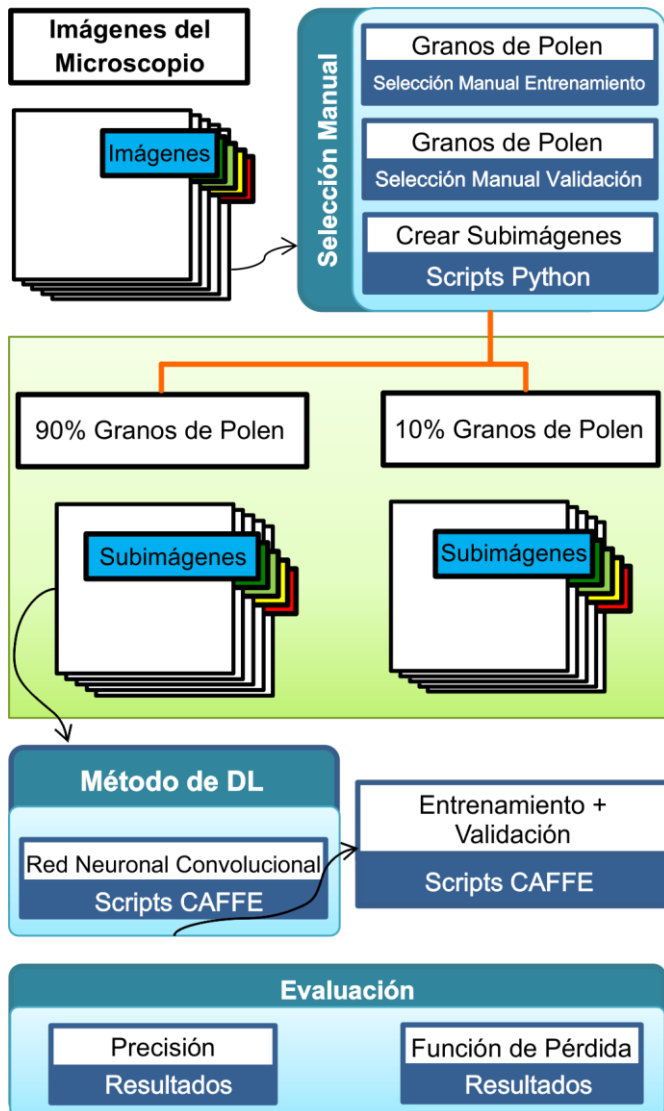


Fig. 1. Proceso de Clasificación de Granos de Polen.

Posteriormente, las capas de agrupamiento, además de reducir las dimensiones de los mapas de características de los granos de polen, tienen el efecto secundario de incrementar la robustez de la extracción, las operaciones de agrupamiento más comunes son Promedio y Máximo. Se pueden extraer altos índices de características de los granos de polen, incrementando la cantidad de capas Convolucionales y de Agrupamiento.

Finalmente, las capas Completamente Conectadas (FC, por sus siglas en inglés, Fully Connected), realizan la tarea de interpretar y clasificar correctamente las características extraídas de las imágenes de los granos de polen; las capas FC constan de un número finito de neuronas simples que intercambian información entre sí, regularmente tienen un gran número de entradas provenientes de los mapas de características de la capa previa o de las salidas de las neuronas que la preceden; la regresión *Softmax* es comúnmente utilizada por su excelente distribución de probabilidad a las salidas.

### III. SECCIÓN EXPERIMENTAL

#### A. Conjunto de Imágenes y Configuración Experimental

Este trabajo fue evaluado usando el conjunto de imágenes público POLEN23E [35], el cual está compuesto por 23 géneros diferentes de granos de polen pertenecientes a 16 diferentes familias, cada género cuenta con 35 imágenes (muestras) *RGB*, las cuales fueron recopiladas con un microscopio digital, tomando fotografías en diferentes ángulos; obteniendo un total de 805 imágenes en formato *JPG* con diferentes dimensiones y resoluciones.

Se analizaron 19 géneros (14 familias) del conjunto de imágenes anteriormente mencionado, esto debido a su alta concentración en la República Mexicana [36], [37]; a continuación, la Fig. 2. ilustra los géneros analizados.



Fig. 2. Granos de Polen a Clasificar.

### B. Aumentando el Conjunto de Imágenes

La técnica DA, es ampliamente utilizada, ya que comúnmente aumenta el rendimiento de las CNN, específicamente cuando el conjunto de imágenes es limitado. Entre todas las posibles variaciones de imágenes, la invariancia a la orientación es muy importante en este sistema, ya que los biólogos no siguen un protocolo específico durante la adquisición de la imagen con el microscopio.

En este enfoque, fueron consideradas 8 rotaciones por cada muestra de grano de polen  $p$ , obteniendo un conjunto aumentado de 8 imágenes. Las transformaciones geométricas proyectivas o afines, no fueron consideradas ya que las muestras con los granos de polen son colocadas por debajo de los objetivos del microscopio y son ortogonales a la superficie de la muestra.

El proceso de DA para este caso es mostrado y descrito a continuación, en la Fig. 3.




Fig. 3. Técnica DA: (a) Imagen original, (b) Imagen rotada, (c) El rectángulo interior (verde) contiene gran cantidad de características (píxeles) del grano de polen, (d) – (f) Recortes cuadrados que contienen vistas parciales del grano de polen.

El primer paso, es generar un conjunto de versiones rotadas a partir de cada imagen de entrada  $\{X_p\}$ .

Al rotar las imágenes, se agregan automáticamente áreas que no existían originalmente, por lo que fue necesario extraer las secciones con mayor cantidad de características originales (rectángulos de la Fig. 3.); y se analizó que esta extracción de características (rectángulos) hace perder cierta información de los granos de polen, pero a su vez mejora los resultados, ya que a pesar de perder parcialmente cierta información, al final se considera todo el conjunto de versiones rotadas, obteniendo de vuelta la información parcialmente perdida.

Finalmente, las imágenes obtenidas fueron redimensionadas a  $96 \times 96$  (píxeles), representadas por el tensor:

$$\widetilde{X}_v^p \in \mathbb{R}^{96 \times 96} \quad (1)$$

con  $v = [1, \dots, 8]$ ; en donde  $\widetilde{X}_v^p$  representa un conjunto extendido de imágenes, siendo  $p$  una imagen de grano de polen y  $v$  las ocho nuevas visualizaciones (rotaciones) de  $p$ ; respectivamente.

El conjunto de imágenes final, fue dividido en dos subconjuntos, uno de validación y otro de entrenamiento, asignando el 10% de las muestras al subconjunto de validación y el restante 90% de las muestras al subconjunto de entrenamiento.

### C. Tarea de Clasificación de Granos de Polen - Evaluando el Entrenamiento From Scratch

En esta sección de experimentos, se evaluó, como las diferentes arquitecturas diseñadas ayudan a mejorar el rendimiento de la clasificación, la efectividad de las arquitecturas está dada por la precisión en porcentaje.

Como se puede observar en la Tabla 1 los mejores resultados han sido conseguidos por la arquitectura 3, alcanzando una precisión de 89.64% y trabajando a una velocidad de 6,826 cuadros por segundo (fps, por sus siglas en inglés, frames per second). Éstos resultados fueron obtenidos al entrenar el modelo durante 400 épocas.

TABLA I  
PRECISIÓN & TIEMPO DE LOS MODELOS PROPUESTOS

Modelo	Arquitectura	Precisión (%)	Tiempo (ms)
1	C+C+A+C+C+F	83.98%	7.88253
2	C+A+C+A+C+A+C+F	81.77%	3.99838
3	C+C+A+C+C+A+C+F	<b>89.64%</b>	<b>6.82598</b>
4	C+A+C+A+C+A+C+A+C+F	85.05%	4.04526
5	C+C+A+C+C+A+C+C+F	89.13%	5.10634
6	C+A+C+A+C+A+C+A+C+A+C+F	87.22%	4.88111

A la entrada del modelo se ingresa un tensor de dimensión  $[4788 \times 96 \times 96 \times 3]$ , el cual es procesado por 25 kernels convolucionales (C) de dimensión  $13 \times 13$  con *stride* de 1, la salida es normalizada y procesada por la función de activación ReLU, la segunda capa procesa los datos de salida de la primera con una capa convolucional de 50 kernels de dimensión  $9 \times 9$  con *stride* de 1, nuevamente la salida es normalizada y procesada por la función de activación ReLU, la siguiente es una capa de agrupamiento (A) de dimensión  $2 \times 2$  con *stride* de 2, las capas consecutivas presentan las siguientes características: 100,  $7 \times 7$ , 250,  $5 \times 5$ , una capa de (A) de dimensión  $2 \times 2$  con *stride* de 2, posteriormente una capa (C) de 250,  $5 \times 5$ , y una capa de (A) de dimensión  $2 \times 2$  con *stride* de 2, seguida de una FC (F) de 1024 neuronas, finalmente, una capa de salida (S) con 19 neuronas, la cual tiene como propósito clasificar cada imagen de entrada en una de las 19 clases conocidas, utilizando una función de activación Softmax, para determinar las probabilidades de cada clase. Adicionalmente, fue anexada una capa *Dropout* de radio 0.5, entre F y S, esto con la finalidad de evitar el sobreentrenamiento [38].

A continuación, en la Fig. 4. se presenta detalladamente el modelo de CNN propuesto.






Fig. 4. Modelo de Red Neuronal Convocional Propuesto.

Al analizar la Tabla I se observa que la capacidad de expresión de las CNN se ve mejorada con el aumento en la profundidad, esto debido a la incorporación de diversas capas Convolucionales y de agrupamiento (las cuales son las encargadas de extraer los rasgos principales de las imágenes), por lo que existe una mejora relativa en el rendimiento de la arquitectura 3 (precisión), pero a su vez se observa una pérdida significativa en la velocidad (fps); cabe mencionarse que a medida que aumenta la profundidad de la red, el consumo de memoria será cada vez mayor y es posible que el rendimiento de la red no mejore, como en los Modelos 4, 5, y 6.

#### D. Tarea de Clasificación de Granos de Polen – Evaluando el Transfer Learning

En esta sección de experimentos, se desarrolló la implementación del método de TL en el modelo de CNN previamente entrenado AlexNet, el cual es utilizado para evaluar al sistema propuesto en este trabajo. Esta evaluación es desarrollada con base a los resultados de velocidad (fps) y precisión en porcentaje obtenidos al realizar el TL a esta red.

El primer paso, consistió en descargar los parámetros del modelo CNN AlexNet desde BAIR [39], como segundo paso, se modificó la capa de entrada de  $224 \times 224 \times 3$  a  $96 \times 96 \times 3$  pixeles, el tercer paso consiste en ajustar las salidas de la última FC a 19, finalmente, el modelo se vuelve a entrenar de acuerdo a los hiperparámetros definidos en el solucionador, esto, para generar un mapa de probabilidad para cada imagen de entrada de granos de polen.

En esta etapa, el modelo ha sido ajustado, aprendiendo características muy específicas del conjunto de imágenes de granos de polen a clasificar. Al evaluar la clasificación de este modelo, se observó que, a pesar de no tener la misma resolución para todo el conjunto de imágenes (conjuntos de entrenamiento y validación), estas resoluciones son lo suficientemente altas para diferenciar y clasificar correctamente los granos de polen.

Los resultados obtenidos del TL en el modelo de CNN AlexNet, muestran un gran desempeño, reportando una precisión de 95.26% y procesando a una tasa de 6,653 fps (6.65316 ms).

#### E. Detalles sobre los Procesos de Aprendizaje y Evaluación

En esta sección se proporcionan algunos detalles útiles acerca del proceso de aprendizaje de las CNN. Como ya se mencionó, se utilizó el modelo de CNN AlexNet con TL y se ajustó la red usando el conjunto de imágenes aumentado de granos de polen.

La arquitectura de CNN propuesta en este trabajo, fue entrenada, usando un solucionador Descenso de Gradiente

Estocástico (SGD, por sus siglas en inglés, *Stochastic Gradient Descent*), con una tasa de aprendizaje de 0.001 y *momentum* de 0.9, el método de distribución *Gaussian* fue utilizado para inicializar los pesos en cada capa. Se utilizó un *batch size* de tamaño 25, para evitar exceder la capacidad de la memoria embebida en la GPU.

Se entrenó el modelo AlexNet usando un solucionador SGD, con una tasa de aprendizaje de 0.0001 y *momentum* de 0.9. Se utilizó un *batch size* de tamaño 32.

#### F. Entorno de Programación y Librerías

Los métodos presentados en este trabajo fueron implementados en el entorno de trabajo *Caffe* [40], en la plataforma NVIDIA Jetson TX2 Developer Kit, la cual cuenta con 2 Denver 64-bit CPUs + Quad-Core A57 Complex, 256 NVIDIA CUDA cores con arquitectura NVIDIA Pascal™ GPU y memoria RAM de 8 GB L128 bit DDR4 trabajando a una frecuencia de 1.2 GHz.

#### G. Resultados

En esta sección se evalúa el desempeño del sistema de DL propuesto, los resultados presentados en la Tabla II, están basados en las métricas Tasa de Clasificación Correcta (CCR, por sus siglas en inglés, Correct Classification Rate), Precisión, Medida F1 (F1-Score, por sus siglas en inglés), Sensibilidad y Especificidad, comúnmente utilizadas para la evaluación de los sistemas de clasificación automática. Estos resultados corresponden a las implementaciones de los métodos TL y entrenamiento FS en la etapa de validación, así como a trabajos relacionados. Como se puede observar, los métodos de TL (CNN TL AlexNet) y entrenamiento FS (CNN Modelo 3) reportan los mejores resultados en todas las métricas, validando así, su buen funcionamiento.

TABLA II  
RENDIMIENTOS DE LOS DIFERENTES MÉTODOS

Métodos	BOW + SVM [25]	CNN Modelo 3	CNN TL AlexNet
CCR (%)	74.03	89.64	95.26
Precision	-	0.8712	0.9403
F1-Score	0.7403	0.8964	0.9526
Sensibilidad	-	0.8757	0.9411
Especificidad	-	0.9073	0.9696

Al analizar los resultados presentados por [25], se concluye que los métodos implementados en este trabajo, en particular CNN Modelo 3, a pesar de contar con menos parámetros que CNN TL AlexNet, realiza adecuadamente el proceso de clasificación con una precisión superior a 89%, esto, calculado a partir de la matriz de confusión correspondiente.

En la Fig. 6, la cantidad de Verdaderos Positivos es ligeramente mayor que en la Fig. 5; los métodos implementados son capaces de clasificar correctamente la mayor cantidad de granos de polen, teniendo como resultados principales, índices de CCR muy favorables para ambos métodos.




Fig. 5. Matriz de Confusión de CNN Modelo 3.




Fig. 6. Matriz de Confusión de CNN TL AlexNet.

Para efectuar un análisis comparativo entre los dos métodos implementados en este trabajo, en cuanto a complejidad computacional (en GPU) se refiere, los incisos C y D respectivamente, describen las velocidades de los sistemas al desarrollar las predicciones (en fps). CNN Modelo 3, destaca por su gran velocidad, desarrollando las predicciones a una tasa de 6,826 fps, mientras que CNN TL AlexNet, desarrolla las predicciones a una tasa de 6,653 fps.

En lo referido a la cantidad de parámetros, CNN Modelo 3 destaca por su limitada cantidad, contando con 9,835,881 parámetros, mientras que CNN TL AlexNet, cuenta con 56,936,480 parámetros.

Finalmente, en Fig. 7 y Fig. 8, se muestra el comportamiento de la Precisión y Función de Pérdida durante las etapas de entrenamiento y validación de CNN Modelo 3. Al analizar éstos comportamientos, se observa que CNN Modelo 3, alcanza un 89.64% de precisión en la etapa de validación y un 96.57% en la etapa de entrenamiento, así mismo se obtienen valores correspondientes a la Función de Pérdida de 0.6 y 0.2, en las etapas de validación y entrenamiento, respectivamente.

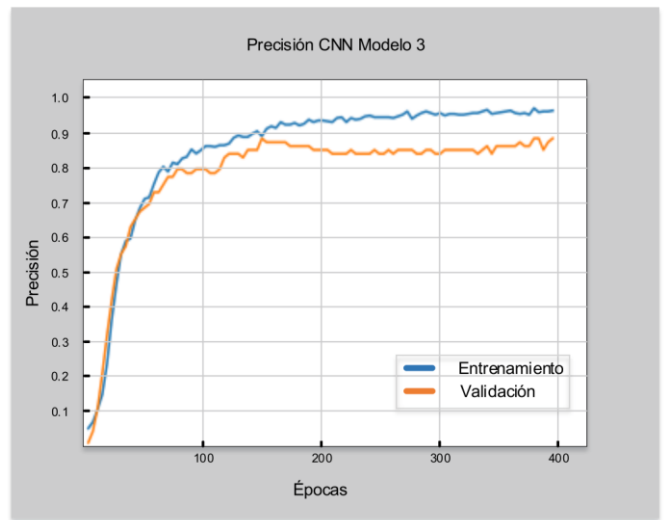


Fig. 7. Gráfica de Precisión durante el Entrenamiento y Validación.

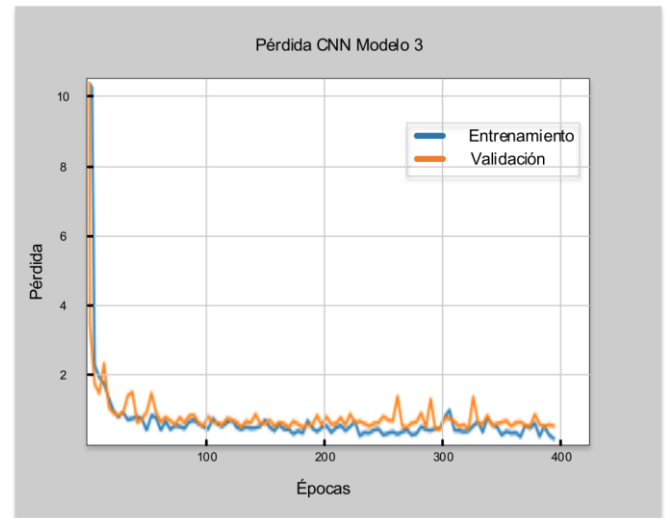


Fig. 8. Gráfica de la Función de Pérdida durante el Entrenamiento y Validación.

### H. Comparación con el Estado-del-Arte

En esta sección se evalúa el rendimiento del sistema de clasificación automática de granos de polen propuesto, el cual es entrenado con un conjunto de imágenes aumentado. En la Tabla III se muestra la comparación entre el método propuesto en este trabajo y los 12 trabajos relacionados más recientes encontrados en el Estado-del-Arte.

TABLA III  
COMPARACIÓN CON EL ESTADO DEL ARTE

Trabajos Relacionados	Clasificadores	CCR (%)
[22]	T. de Wavelet + SVM	79%
[23]	K-NN	93.30%
[24]	Bosques Aleatorios	90.14%
[25]	BOW + SVM	74.03%
[26]	CST + BOW + C-SVC	64%
[27]	AlexNet CNN (TL)	85.10%
[28]	AlexNet CNN (TL)	89.95%
	CNN (FS)	84.47%
[29]	AlexNet CNN (TL) + CDL	97.86%
[31]	DenseNet-121 CNN (TL)	96.24%
	DenseNet-121 CNN (FS)	88.73%
[32]	VGG16 CNN (TL) + RNN	100%
	VGG16 CNN (FS) + RNN	95.91%
[33]	CNN (FS)	95.9%
[34]	CNN (FS)	83%
<b>Trabajo Presentado</b>	CNN Modelo 3	<b>89.64%</b>
	CNN TL AlexNet	<b>95.26%</b>

Considerando los dos métodos implementados en este trabajo y recurriendo al CCR como principal métrica de evaluación, se observa que ambos métodos obtienen los índices de CCR más favorables, esto con respecto a [22], [23], [24], [25], [26], [27], [28], [31] y [34]; sin embargo, al analizar otros trabajos relacionados como [29], [31], [32] y [33], se observa un margen de diferencia muy reducido en el CCR.

Por otro lado, el modelo propuesto presenta una limitada cantidad de parámetros, aproximadamente 50% menos que [28] y 90.94% menos que los reportados por [32]; además, presenta una gran velocidad de procesamiento, con una tasa muy favorable de fps.

#### IV. CONCLUSIÓN

La clasificación de granos de polen es de gran importancia en diversos campos de la biología, sin embargo, la clasificación manual es un método que tiene poco control sobre el error humano. En este trabajo, se propone y analiza un modelo basado en CNN para la clasificación de 19 géneros diferentes de granos de polen pertenecientes a 14 distintas familias, que son encontrados en altas concentraciones en la República Mexicana; el modelo propuesto presenta altos índices en las métricas de clasificación, alta velocidad de procesamiento (fps) y limitada cantidad de parámetros. Los resultados de las métricas de clasificación presentan altos índices en CCR, F1-score y Especificidad, alrededor del 90%, estos índices son comparables con modelos predefinidos como CNN TL AlexNet y mayores a los reportados en diversos trabajos relacionados. En lo referido a la alta velocidad de procesamiento, el modelo propuesto procesa 2.5% más rápido, trabajando a 6,826 fps mientras que CNN TL AlexNet trabaja a 6,653 fps. Con respecto a la limitada cantidad de parámetros, el modelo propuesto cuenta con 9,835,881 parámetros, esto es, 82.72% menos que el modelo de CNN TL AlexNet.

Una de las desventajas observadas en los resultados experimentales, fue el índice CCR de CNN Modelo 3, sin embargo, se considera adecuado su uso ya que fue diseñado de acuerdo a su aplicación, con un índice CCR similar al de CNN TL AlexNet, obteniendo como ventaja, mayor disponibilidad de memoria para extender los alcances de este sistema.

Las futuras líneas de investigación para este sistema, comprenden la experimentación con Redes Neuronales Residuales, así como el diseño de nuevos bloques considerando otros aspectos que son de gran interés para biólogos como es, la concentración (cantidad) de granos de polen por familia y género en las muestras a procesar [9], [10].

#### AGRADECIMIENTOS

Se agradece a la Dra. Margarita Ortega Cisneros, Directora del Departamento de Inmunología y Alergias en el Centro Médico de Occidente en Guadalajara, Jalisco, México; por la aportación de información para el desarrollo de este trabajo.

#### REFERENCIAS

- [1] M. B. Ruiz Zapata and M. García Anton, "La Palinología y su Aplicación al Estudio de la Reconstrucción de la Vegetación durante el Cuaternario: Consideraciones Generales," *Revista de Geología*, no.1, pp. 77-84, 1987. [Online]. Available: <https://ebuah.uah.es/dspace/handle/10017/9596>
- [2] M. A. Magaña Magaña, L. L. Salazar Barrientos, J. R. Sanginés García and M. E. Tavera Cortés, "Productividad de la Apicultura en México y su Impacto sobre la Rentabilidad," *Revista Mexicana de Ciencias Agrícolas*, vol.7, no.5, August 2016. [Online]. Available: [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S2007-09342016000501103](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-09342016000501103)
- [3] E. Ramírez-Arriaga, A. Martínez-Bernal, N. Ramírez Maldonado and E. Martínez-Hernández, "Análisis Palinológico de Miel y Cargas de Polen de *Apis mellifera* (Apidae) de la Región Centro y Norte del Estado de Guerrero, México," *Botanical Sciences*, vol.94, no.1, pp. 141-156, March 2016. [Online]. Available: [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S2007-42982016000100141](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-42982016000100141)
- [4] F. M. Salinas-Márquez, J. G. Flores-Trujillo, J. Helenes, M. A. Téllez-Duarte and F. J. Aranda-Manteca, "Paleoecología y Cronoestratigrafía de las Diatomeas del Miembro Los Indios en la Mesa La Misión, del Mioceno de Baja California, México," *Sociedad Geológica Mexicana & Instituto de Geología UNAM*, vol.68, no.3, pp. 537-552, December 2016. [Online]. Available: [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-33222016000300537](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-33222016000300537)
- [5] E. Ortiz-Torres, A. Carballo-Carballo, A. Muñoz-Orozco and F. B. González-Cossio, "Efecto de la Dispersión de Polen en la Producción de Semilla de Maíz, en Texcoco, México," *Agronomía Mesoamericana*, vol. 21, no. 2, pp.289-297. December 2010. [Online]. Available: [https://www.scielo.sa.cr/scielo.php?pid=S1659-13212010000200008&script=sci\\_arttext](https://www.scielo.sa.cr/scielo.php?pid=S1659-13212010000200008&script=sci_arttext)
- [6] T. González-Mendoza, M. Bedolla-Barajas, T. R. Bedolla-Pulido, J. Morales-Romero, N. A. Pulido-Guillén, S. Lerma-Partida and C. Meza-López, "La Prevalencia de Rinitis Alérgica y Dermatitis Atópica en Adolescentes Tardíos Difiere de Acuerdo con el Sexo," *Revista Alergia México*, vol. 66, no. 2, pp.147-153, June 2019. [Online]. Available: <http://revistaalergia.mx/ojs/index.php/ram/article/view/521>
- [7] World Allergy Organization. "In-Depth Review of Allergic Rhinitis," WAO, Milwaukee, MI, USA, Jun. 2015. [Online]. Available: <https://www.worldallergy.org/education-and-programs/education/allergic-disease-resource-center/professionals/in-depth-review-of-allergic-rhinitis>
- [8] O. Pfaar, K. Karatzas, K. Bastl, U. Wergler, J. Buters, U. Darsow, P. Demoly, S. Durham, C. Galán, R. Gehrig, R. van Wijk, L. Jacobsen, N. Katsifarakis, L. Klimek, A. Saarto, M. Sofiev, M. Thibaudon, B. Werchan and K. Bergmann, "Pollen season is reflected on symptom load for grass and birch pollen-induced allergic rhinitis in different



- geographic areas-An EAACI Task Force Report,” *Allergy*, vol. 75, no. 5, pp. 1099-1106, May 2020.
- [9] K. A. Holt and K. D. Bennett, “Principles and Methods for Automated Palynology,” *New Phytologist Trust*, vol. 203, pp. 735-742, April 2014.
- [10] S. S. Alotaibi, S. M. Sayed, M. Alosaimi, R. Alharthi, A. Banjar, N. Abdulqader and R. Alhamed, “Pollen Molecular Biology: Applications in the Forensic Palynology and Future Prospects: A Review,” *Saudi Journal of Biological Sciences*, vol. 27, no. 5, pp. 1185-1190, May 2020.
- [11] Ian Goodfellow, Yoshua Bengio, Aaron Courville, “Convolutional Networks,” in *Deep Learning*, Cambridge, Massachusetts, USA, MIT Press 2016, Cap. 9, pp. 326-366. [Online]. Available: <http://www.deeplearningbook.org>
- [12] J. Salas, F. Vidal, and J. Martinez-Trinidad, “Deep Learning: Current State,” *IEEE Latin America Transactions*, vol. 17, no. 12, pp. 1925-1945 December 2019.
- [13] Y. Le Cun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel, “Handwritten Digit Recognition with a Back-Propagation Network,” in *Advances in Neural Information Processing Systems 2 (NIPS)*, 1990, pp. 396-404.
- [14] A. Krizhevsky, I. Sutskever and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” in *Advances in Neural Information Processing Systems (NIPS)*, 2012, pp. 1097-1105.
- [15] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich, “Going Deeper with Convolutions,” in *Proceedings IEEE Conference on Computer Vision and Pattern Recognition*, June 2015, pp. 1-9.
- [16] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” *arXiv preprint arXiv 1409.1556*, 2014.
- [17] M. D. Zeiler and R. Fergus, “Visualizing and Understanding Convolutional Networks,” in *European Conference on Computer Vision*. Springer, 2014, vol. 8689, pp. 818-833.
- [18] J. Liu, F. Chen, C. Pan, M. Zhu, X. Zhang, L. Zhang and H. Liao, “A Cascaded Deep Convolutional Neural Network for Joint Segmentation and Genotype Prediction of Brainstem Gliomas,” *IEEE Transactions on Biomedical Engineering*, vol.65, pp. 1943-1952, September 2018.
- [19] A. Cabrera-Ponce, L. Rojas-Pérez, J. Carrasco-Ochoa, J. Martínez-Trinidad and J. Martínez-Carranza, “Gate Detection for Micro Aerial Vehicles Using a Single Shot Detector,” *IEEE Latin America Transactions*, vol. 17, no. 12, pp. 2045-2052, December 2019.
- [20] R. da Silva and A. de Carvalho, “Automatic Classification of Breast Lesions Using Transfer Learning,” *IEEE Latin America Transactions*, vol. 17, no. 12, pp. 1964-1969 December 2019.
- [21] P. Dhabe, P. Vyas, D. Ganerwal and A. Pathak, “Pattern Classification Using Updated Fuzzy Hyper-Line Segment Neural Network and It’s GPU Parallel Implementation for Large Datasets Using CUDA,” in *International Conference on Computing, Analytics and Security Trends (CAST)*, pp. 24-29, December 2016.
- [22] D. S. da Silva, L. N. Balta Quinta, A. Barbosa Gonçalves, H. Pistori and M. R. Borth, “Application of Wavelet Transform in the Classification of Pollen Grains,” *African Journal of Agricultural Research*, vol. 9, no. 10, pp. 908-913, March 2014.
- [23] S. W. Punyasena, D. K. Tchong, C. Wesseln and P. G. Mueller, “Classifying Black and White Spruce Pollen Using Layered Machine Learning,” *New Phytologist Trust*, vol. 196, pp. 937-944, September 2012.
- [24] M. K. Sobol, L. Scott, S. A. Finkelstein, “Reconstructing Past Biomes States Using Machine Learning and Modern Pollen Assemblages: A Case Study from Southern Africa,” *Quaternary Science Reviews*, vol. 212, pp. 1-17, April 2019.
- [25] C. N. M. Rodrigues, A. Barbosa Gonçalves, G. G. da Silva and H. Pistori, “Evaluation of Machine Learning and Bag of Visual Words Techniques for Pollen Grains Classification,” *IEEE Latin America Transactions*, vol. 13, no. 10, pp. 3498-3504 October 2015.
- [26] A. B. Gonçalves, J. S. Souza, G. G. da Silva, M. P. Cereda, A. Pott, M. H. Naka and H. Pistori, “Feature Extraction and Machine Learning for the Classification of Brazilian Savannah Pollen Grains,” *PLoS ONE*, vol. 6, no. 11, pp. 1-20, June 2016.
- [27] H. Menad, F. Ben-Naoum and A. Amine, “Deep Convolutional Neural Network for Pollen Grains Classification,” in *Journée d’Etude sur la Recherche en Informatique (JERI)*, pp. 22-32, April 2019.
- [28] A. Daood, E. Ribeiro and M. Bush, “Pollen Grain Recognition Using Deep Learning,” in *International Symposium on Visual Computing*, vol. 10072, pp. 321-330, December 2016.
- [29] V. Sevillano, K. Holt and J. L. Aznarte, “Precise Automatic Classification of 46 Different Pollen Types with Convolutional Neural Networks,” *PLoS ONE*, vol. 15, no. 6, pp. 1-15, June 2020.
- [30] K. Holt, G. Allen, R. Hodgson, S. Marsland and J. Flenley, “Progress towards an automated trainable pollen location and classifier system for use in the palynology laboratory,” *Review of Palaeobotany and Palynology*, vol. 167, pp. 175-183, August 2011.
- [31] A. R. de Geus, C. A. Barcelos, M. A. Batista and S. F. da Silva, “Large-Scale Pollen Recognition with Deep Learning,” in *27th European Signal Processing Conference (EUSIPCO)*, 2019, pp. 1-5.
- [32] A. Daood, E. Ribeiro and M. Bush, “Sequential Recognition of Pollen Grain Z-Stacks by Combining CNN and RNN,” in *The Thirty-First International Florida Artificial Intelligence Research Society Conference (FLAIRS-31)*, pp. 8-13, 2018.
- [33] N. Khanzhina, E. Putin, A. Filchenkov and E. Zamyatina, “Pollen Grain Recognition Using Convolutional Neural Network,” in *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)*, pp. 409-414, April 2018.
- [34] J. Schiele, F. Rabe, M. Schmitt, M. Glaser, F. Häring, J. O. Brunner, B. Bauer, B. Schuller, C. Traidl-Hoffmann and A. Damialis, “Automated Classification of Airborne Pollen using Neural Networks,” in *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 4474-4478, July 2019.
- [35] A. Barbosa Gonçalves, (2015): POLLEN23E. figshare. Dataset. [Online]. Available: <https://doi.org/10.6084/m9.figshare.1525086.v1>
- [36] A. Rosas-Alvarado, M. Bautista-Huerta and G. Velázquez-Sámamo, “Atlas de los Pólenes Alergénicos de Mayor Relevancia en México,” *Revista Alergia México*, vol. 58, no.3, pp. 162-170. July 2011. [Online]. Available: <https://www.elsevier.es/es-revista-revista-alergia-mexico-336-pdf-X0002515111345183>
- [37] Universidad Nacional Autónoma de México (2019): Red Mexicana de Aerobiología (REMA). [Online]. Available: [http://rema.atmosfera.unam.mx/rema/REMA\\_SEMAFORO.aspx](http://rema.atmosfera.unam.mx/rema/REMA_SEMAFORO.aspx)
- [38] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, “Dropout: A Simple Way to Prevent Neural Networks from Overfitting,” *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929-1958, June 2014.
- [39] University of California Berkeley (2020): Berkeley Artificial Intelligence Research (BAIR). [Online]. Available:[http://dl.caffe.berkeleyvision.org/bvlc\\_alexnet.caffemodel](http://dl.caffe.berkeleyvision.org/bvlc_alexnet.caffemodel)
- [40] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama and T. Darrell, “Caffe: Convolutional Architecture for Fast Feature Embedding,” *arXiv preprint arXiv 1408.5093*, August 2014.



**Juan Manuel Ruiz-Varela.** Obtuvo el grado de Maestro en Ciencias de la Ingeniería en el Centro de Investigación y de Estudios Avanzados del IPN (CINVESTAV), Guadalajara, México en 2016. Actualmente es estudiante de Doctorado en Ciencias de la Ingeniería en el Centro de Investigación y de Estudios

Avanzados del IPN (CINVESTAV), Guadalajara, México. Sus áreas de investigación son Aprendizaje de Máquinas y Visión por Computadora.



**Susana Ortega-Cisneros.** Recibió el grado de Maestro en Ciencias de la Ingeniería en el Centro de Investigación y de Estudios Avanzados (CINVESTAV), Zacatenco IPN, Ciudad de México, México; y el grado de Doctor en Ciencias de la Computación y Telecomunicaciones en la Universidad Autónoma de Madrid (UAM), Madrid, España. Actualmente es Investigador Titular en el CINVESTAV del IPN, Unidad Guadalajara. Sus intereses de investigación se centran en el diseño de arquitecturas digitales basadas en FPGAs, microprocesadores y sistemas electrónicos aplicados a la biomedicina.



**Pablo Moreno.** Obtuvo el grado de Maestro en Ciencias en Ingeniería Eléctrica en el Instituto Tecnológico y de Estudios Superiores de Monterrey (ITESM), Monterrey, México en 1989 y el grado de Doctor en Ciencias en Ingeniería Eléctrica (Área de Electrofísica) en la Universidad Estatal de Washington, Pullman, WA, Estados Unidos en 1997. Actualmente es Investigador Titular en el CINVESTAV del IPN, Unidad Guadalajara. Sus intereses de investigación comprenden electrofísica, propagación de ondas y compatibilidad electromagnética en sistemas eléctricos y electrónicos.



**Jorge Rivera.** Recibió los grados de Maestro y Doctor en Ciencias de la Ingeniería Eléctrica del Centro de Investigación y de Estudios Avanzados (CINVESTAV) del Instituto Politécnico Nacional (IPN), Guadalajara, México en 2001 y 2005, respectivamente. Actualmente está comisionado como profesor de Cátedras CONACYT en el CINVESTAV del IPN Unidad Guadalajara. Sus intereses de investigación se centran en el diseño de algoritmos de control con su correspondiente implementación en dispositivos digitales reconfigurables.



**Miguel Rivera Acosta.** Recibió el grado de Maestro en Ciencias en Ingeniería Eléctrica del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV), Guadalajara, México en 2016. Actualmente, es alumno de Doctorado en Ciencias en el Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV), Guadalajara, México. Sus intereses de investigación son, diseño ASIC para procesamiento digital de imágenes y visión por computadora.