

Guillermo Bernabó¹[0009-0006-9129-3276], Maria Elena Buemi²[0009-0008-1076-4035] and Agustín Sanguinetti^{3,4,5,6}[0000-0003-3808-3131]

¹ Maestría de Explotación de Datos y Descubrimiento del Conocimiento, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Argentina

² Departamento de Computación, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Argentina.

³ Departamento de Biodiversidad y Biología Experimental, Facultad de Ciencias Exactas y Naturales, Universidad de Buenos Aires, Argentina.

⁴ Instituto de Biodiversidad y Biología Experimental y Aplicada, CONICET – Universidad de Buenos Aires, Argentina.

⁵ Facultad de Bromatología, Universidad Nacional de Entre Ríos, Argentina.

⁶ sangos@gmail.com

Artificial intelligence applied to the analysis of pollen of apicultural interest

Abstract. Identification and quantification of pollen grains in honey samples are indispensable tools for determining floral composition and geographical origin. In this way, value can be added to the product while preventing potential fraud. The traditional method involves specialized analysts spending long periods at the microscope and can be automated through the use of artificial intelligence. Here, we present an automatic classification trial of pollen grains from 10 species present in the apicultural flora of Entre Ríos, utilizing four pre-trained convolutional neural network models and different parameters in multi-class and binary classifications. Microscopy images were obtained using widely available equipment, and individual pollen grains were extracted using standard segmentation algorithms. Using widely available microscopy equipment and standard segmentation algorithms, we achieved a maximum multi-class accuracy of 93% with ResNet-50 and DenseNet-121 networks (RGB images). The classification performance for particular species depended heavily on the species in question and, in some cases, on the specific network used. While binarization improved species identification precision, it did not consistently enhance recall. These results highlight the potential of this method for quantifying the pollen content of floral species of particular commercial interest and its potential application in the validation of monofloral honeys.

Keywords: Deep Learning, Convolutional Neural Networks, Melissopalynology, Monofloral honey, OpenCV, Honey typification.

Inteligencia artificial aplicada al análisis de polen de interés apícola

Resumen. La identificación y cuantificación de los granos de polen en muestras de miel es una herramienta indispensable para determinar su composición floral y su origen geográfico. Esto permite agregar valor al producto y mitigar posibles fraudes. El método tradicional implica el uso de analistas especializados por largos tiempos frente al microscopio y puede ser automatizado mediante el uso de inteligencia artificial. Aquí presentamos un ensayo de clasificación automática de granos de polen de 10 especies presentes en la flora apícola de Entre Ríos utilizando cuatro modelos de redes neuronales convolucionales pre entrenadas y diferentes parámetros en clasificaciones multicategorías y binarias. Las imágenes de microscopía fueron obtenidas con equipos de amplia disponibilidad y los granos de polen

individualmente extraídos por algoritmos de segmentación de uso habitual. La mayor exactitud de clasificación multicategoría (93%) se obtuvo con las redes ResNet-50 y DenseNet-121 utilizando imágenes RGB. El desempeño clasificatorio varió significativamente según la especie analizada y, en menor medida, la arquitectura de red empleada. La binarización mejoró la precisión de identificación de especies, aunque no necesariamente su tasa de recupero. Los resultados resaltan la potencialidad del método para cuantificar el contenido polínico de especies florales de particular interés comercial y su potencial aplicabilidad en la validación de mieles monoflorales.

Palabras clave: Aprendizaje profundo, Redes Neuronales Convolucionales, Melisopalinología, Miel monofloral, OpenCV, Tipificación de miel.

1. Introducción

Argentina se ubica entre los principales países productores y exportadores de miel. Su cadena productiva moviliza a más de 35.000 productores registrados con 4 millones de colmenas distribuidas por todo el país y emplea de forma directa e indirecta a más de 100.000 personas (SADA 2026, MAGyP 2023). Durante el año 2024 exportó 78 mil toneladas por un monto de 170 millones de dólares (BM 2024), que se traducen en un precio promedio de 2,2 dólares por kg de miel. En cambio, Nueva Zelanda, otro jugador de importancia, exportó 11 mil toneladas a un precio promedio de 23 dólares por kg. Esta diferencia de un orden de magnitud radica en que Argentina exporta casi la totalidad de su producción mezclada en barriles a granel, mientras que Nueva Zelanda exporta miel fraccionada con trazabilidad y certificación de origen.

La extensión geográfica de Argentina junto a la multiplicidad de sus ambientes naturales redundan en una producción apícola con fuerte identidad territorial. Cada tipo de vegetación sobre la cual están emplazadas las colmenas produce mieles con características físico-químicas y organolépticas características. Esta riqueza de mieles diversas es la materia prima sobre la cual obrar a fin de agregar valor al producto jerarquizándolas a nivel local e internacional. Existen avances alentadores en este aspecto tales como las recientes denominaciones de Indicación Geográfica de mieles monoflorales y poliflorales de distintas partes del país. Estas mieles se exportan de forma fraccionada a valores muy superiores al promedio y tienen la potencialidad para una mayor aceptación en el mercado local por consumidores informados (Tobler & Basilio, 2023).

La normativa nacional e internacional para categorizar mieles según su origen floral está basada en el análisis cuantitativo de los granos en suspensión presentes en la miel (Apablaza et al., 2019). El espectro polínico presente actúa de modo de huella digital de la vegetación circundante al apiario validando su origen botánico y geográfico (Jones y Bryant, 2014). Este análisis es ejecutado por profesionales altamente capacitados y demanda largas jornadas de conteos manuales frente al microscopio óptico. Por lo tanto, una forma de reducir tiempos de análisis y costos asociados, aumentar su accesibilidad y evitar potenciales sesgos y errores es la automatización mediante herramientas de inteligencia artificial (Valiente et al., 2023).

En este sentido, se han desarrollado numerosas aproximaciones a la problemática donde resaltan el uso de redes neuronales convolucionales (CNNs) para la

clasificación automática de imágenes individuales de granos de polen (Viertel & König, 2022). Estas redes deben ser entrenadas con enormes cantidades de imágenes categorizadas y, en su gran mayoría, fueron obtenidas utilizando equipamiento de alto costo y poca accesibilidad. Además, a la fecha, solo un estudio publicado reflejó ensambles de especies específicos de nuestro país (Shammah et al., 2025).

El objetivo general de este trabajo es evaluar la potencialidad del uso de esta tecnología para categorizar mieles monoflorales de acuerdo a la normativa nacional. Para ello, a partir de 10 especies presentes en la flora apícola de Entre Ríos, se utilizan imágenes de microscopía óptica obtenidas con equipamiento de amplia disponibilidad y se ponen a prueba distintas redes neuronales bajo parámetros diversos.

2. Metodología

2.1. Material biológico e imágenes de microscopía

Muestras de polen de diez especies melíferas presentes en la flora apícola de Entre Ríos (Tabla 1) fueron recolectadas manualmente con pinzas a partir de anteras de flores frescas y conservadas en etanol al 70%. Cada especie contó con tres muestras independientes tomadas en localidades y/o temporadas diferentes de modo de capturar parte de la posible variabilidad morfológica de los granos de polen y permitir una mejor generalización a las redes entrenadas (Olsson et al., 2021). Al menos un preparado microscópico semipermanente, montado sobre gelatina-glicerina teñida con fucsina y sellado con parafina (Zarlavsky, 2014) fue realizado para cada muestra polínica sin incluir proceso de acetólisis (Fig. 1A).

Tabla 1. Especies utilizadas como categorías de clasificación y sus sets de entrenamiento y testeo. Estos sets están conformados, respectivamente, por dos y por una muestra independientes entre sí. Se informa su número de imágenes. *:especies incluidas en un experimento de clasificación binario.

Familia	Especie	Entrenamiento	Testeo
Asteraceae	<i>Cirsium vulgare</i>	662	280
Asteraceae	<i>Helianthus annuus</i> *	2356	310
Asteraceae	<i>Solidago chilensis</i>	871	773
Boraginaceae	<i>Echium plantagineum</i> *	5146	1079
Calyceraceae	<i>Acicarpa tribuloides</i>	1277	343
Fabaceae	<i>Lotus</i> sp.*	1905	521
Fabaceae	<i>Trifolium pratense</i> *	1133	198
Oleaceae	<i>Ligustrum lucidum</i>	1906	985
Rhamnaceae	<i>Scutia buxifolia</i> *	2800	1002
Salicaceae	<i>Salix</i> sp.	1485	1102

Imágenes en formato TIFF de microscopía de campo claro de las distintas muestras fueron obtenidas con un microscopio Zeiss Ax10 con un lente objetivo de aumento 10× Zeiss LD A-Plan 421241-9910 de apertura numérica 0.25 y acoplado a una cámara digital Zeiss Axiocam 208 con sensor CMOS color de 3840×2160 píxeles. Cada una de estas imágenes equivalen a un área de 1,13×0,63 mm del preparado microscópico e incluyen granos de polen coloreados con fucsina en diferentes orientaciones espaciales (Fig. 1B,C).

2.2 Identificación, segmentación y extracción de imágenes individuales

La segmentación automática de granos de polen se implementó mediante un *pipeline* utilizando la biblioteca OpenCV (Bradsky 2000). Las imágenes de microscopía óptica se almacenaron en formato TIFF y se procesaron por imagen de forma independiente, preservando la información cromática en el espacio RGB.

Corrección fotométrica. Con el fin de atenuar gradientes de iluminación propios del montaje microscópico (iluminación no homogénea sobre el campo visual), se aplicó una corrección tipo flat-field: en cada canal de color se estimó el componente de baja frecuencia del fondo mediante un filtro gaussiano de núcleo amplio; a continuación, cada valor de píxel se normalizó por dicha estimación y se reclampó al rango 8 bits, manteniendo coherencia cromática entre canales.

Preprocesamiento y binarización. Sobre la imagen corregida, se extrajo la luminancia y se aplicó ecualización adaptativa del histograma con recorte (CLAHE) para mejorar el contraste local sin amplificar excesivamente el ruido. Tras un suavizado gaussiano, se obtuvo una máscara binaria mediante umbralización global de Otsu. En casos en que la fracción de píxeles activos resultaba extrema (casi toda la imagen blanca o negra), se sustituyó el umbral global por un esquema adaptativo gaussiano orientado a recuperar separabilidad objeto-fondo. Sobre la máscara resultante se aplicaron operaciones morfológicas (cierre seguido de apertura) con elemento estructurante elíptico, con el propósito de consolidar regiones de interés y suprimir artefactos finos.

Extracción de candidatos. Se calcularon contornos externos en la imagen binaria y, para cada candidato, se computaron descriptores geométricos estándar. Se filtraron regiones fuera de un rango de área predefinido y se exigieron umbrales mínimos de circularidad, solidez (cociente entre el área del contorno y la de su envolvente convexa) y extensión (cociente entre el área del contorno y la del rectángulo mínimo), con el fin de excluir ruido, fundidos espurios y formas marcadamente alargadas o dentadas. Opcionalmente, el procedimiento consideró dos polaridades de umbralización y se retuvo la que maximizaba el número de contornos que satisfacían los criterios de validez, para robustecer el proceso ante variaciones de contraste.

Recortes y normalización de apariencia. Para cada contorno aceptado, se definió un recorte rectangular ampliado con un margen proporcional al tamaño del *bounding box*. El fondo exterior al grano se anuló mediante enmascarado por el propio contorno. Los recortes se redimensionaron a una plantilla cuadrada fija conservando

la relación de aspecto y rellenando el remanente con color uniforme. Se exportaron dos variantes por grano: una conservando la apariencia cromática tras la corrección fotométrica, y otra sometiendo cada canal a una normalización estadística (por ejemplo, estandarización por media y desviación típica o estiramiento por percentiles) para atenuar variaciones residuales de tinción e iluminación entre muestras.




Fig. 1. Preparado polínico de *Scutia buxifolia* y extracción de imágenes individuales de polen.
A. Portaobjetos con muestra montada en medio gelatina-glicerina-fucsina. B. Imagen RGB obtenida en el microscopio campo claro con objetos identificados para su extracción. C. Imágenes individuales RGB de granos extraídos y reescalados a 224×224 píxeles.

Inspección visual. Cada una de las imágenes resultantes (26134 en total) fueron inspeccionadas de manera manual para eliminar imágenes espúreas tales como suciedad en la muestra, granos de polen superpuestos o incompletos por el recorte de la imagen (Fig. 2).

Este enfoque combina corrección de iluminación, segmentación clásica por umbral adaptativo, regularización morfológica y filtrado geométrico multicriterio, resultando adecuado para escenarios en los que la iluminación del microscopio no es uniforme y se requiere trazabilidad reproducible entre lotes de imágenes.




Fig. 2. Ejemplos de imágenes extraídas con el *pipeline* desarrollado. Cada columna corresponde a una especie de la Tabla 1, en orden consecutivo.

2.3 Entrenamiento de CNNs y experimento *benchmark*

Se diseñó un experimento de *benchmark* para una evaluación exploratoria de la capacidad de cuatro arquitecturas de redes neuronales convolucionales (Tabla 2) pre entrenadas en ImageNet en la tarea de clasificar los granos de polen de las 10 especies en estudio (Tabla 1, Fig. 2). En todos los modelos, se reemplazó la capa de salida original por un cabezal clasificador personalizado que integró capas lineales, normalización por lotes (*batch normalization*), activación *ReLU* y técnicas de regularización mediante *dropout*. Los hiperparámetros utilizados fueron: optimizador *Adam*, tasa de aprendizaje 1.10^{-4} , tamaño de lote 32, épocas máximas 50, paciencia de parada temprana sobre pérdida de validación 5, decaimiento de pesos 1.10^{-4} . La función de pérdida fue entropía cruzada categórica (*CrossEntropyLoss*), suavizado de etiquetas 0,1, *ReduceLROnPlateau* (factor=0,1, paciencia=3) y semilla aleatoria 42. Se seleccionó el *checkpoint* del modelo con menor pérdida de validación para el testeo final. Los entrenamientos y experimentos se realizaron en un servidor dedicado con una placa de video NVIDIA GeForce RTX 3090 con 24 GB de VRAM.

Tabla 2. Redes neuronales convolucionales (CNNs) utilizadas.

Arquitectura	Parámetros	Características	Referencia
ResNet-50	25,6M	Conexiones residuales profundas	He et al., 2016
DenseNet-121	8,0M	Reutilización densa de características	Huang et al., 2017
EfficientNet-B0	5,3M	Arquitectura con escalado compuesto	Tan et al., 2019
MobileNetV3-Large	5,4M	Liviana, orientada a dispositivos móviles	Howard et al., 2019

Cada arquitectura de CNN fue evaluada en dos modos de color: RGB vs. escala de grises. Para esta última, se replicó la luminancia en tres canales para mantener la

compatibilidad con los pesos pre entrenados de ImageNet. Se ejecutaron 8 experimentos en total, resultantes de la combinación factorial de: 4 modelos $\times$ 2 modos de color.

Partición de datos. El dataset de entrenamiento fueron todas las imágenes extraídas (Fig. 2) de dos muestras polínicas independientes por cada categoría (especie). Todas las categorías de clasificación contaron con al menos 662 imágenes de entrenamiento (Tabla 1). A estas imágenes originales se les aplicó un aumento de datos (*data augmentation*) que consistió en volteos horizontales aleatorios, rotación de $\pm 15^\circ$ y variaciones de color, brillo y contraste mediante ColorJitter y RandomResizedCrop de la librería torchvision. El conjunto de validación consistió en un subset estratificado aleatorio, con semilla fijada para reproducibilidad, del 20% extraído del dataset de entrenamiento. El dataset de testeo final consistió en todas las imágenes extraídas de una muestra polínica independiente que no fue incluida previamente en el dataset de entrenamiento y validación. Todas las categorías fueron testeadas con al menos 198 imágenes (Tabla 1).

Evaluación y métricas. El rendimiento global de las redes se determinó mediante exactitud (*accuracy*), Macro-F1, precisión promedio (*average precision*), tasa de recupero promedio (*average recall*) y pérdida (*loss*) con el dataset de testeo final. La capacidad de generalización y los errores de clasificación entre las diez especies de polen se analizaron a través de matrices de confusión normalizadas, curvas de aprendizaje por época y el cálculo de la precisión (*precision*), tasa de recupero (*recall*) y la F1, por categoría. Los cálculos de estas métricas pueden encontrarse en Grandini et al. (2020).

2.4 CNNs dedicadas a la identificación de un único tipo de polen

A fin de evaluar el rendimiento de estas CNNs dedicadas específicamente a la categorización de una única especie de polen se realizaron los mismos experimentos que en 2.3 pero con una clasificación binaria: polen de especie de interés vs. resto de especies agrupadas. Para ello se seleccionaron cinco especies que constituyen mieles monofloras en el país de acuerdo a su porcentaje polínico presente: *Helianthus annuus* "girasol", *Trifolium pratense* "trébol rojo", *Lotus* sp. "tréboles", *Scutia buxifolia* "coronillo" y *Echium plantagineum* "flor violeta". La categoría negativa fue constituida por el agrupamiento de las restantes nueve especies y balanceada con la categoría positiva tanto en entrenamiento como en testeo, para obtener una cantidad similar de imágenes en ambas categorías. Para cada clasificación binaria se calculó la exactitud, la tasa de precisión, la tasa de recupero y la F1.

3. Resultados

En la clasificación de las 10 especies (Tabla 1) de forma individual (2.3), las mejores métricas las obtuvieron las CNNs ResNet-50 y DenseNet-121 con imágenes RGB y DenseNet-121 con escala de grises (Tabla 3). Todas las redes tuvieron una exactitud de testeo superior al 0,90, por debajo de la de su validación. Esto sugiere que no hay sobreajuste (*overfitting*) y que las CNNs generalizan adecuadamente (Figura 3). El

uso de imágenes RGB permitió obtener exactitudes superiores a las logradas con imágenes en escala de grises, aunque esta diferencia no superó al 0,017 por arquitecturas. Para todas las redes se observa una leve mayor precisión por sobre la tasa de recupero (*recall*). Esto indica una tendencia conservativa de estos modelos donde la fracción global de falsos positivos es menor que la de falsos negativos.

Tabla 3. Métricas globales de las arquitecturas en la clasificación de 10 categorías: exactitud de validación y de testeo, Macro-F1, precisión promedio y tasa de recupero promedio. En negrita se destacan los tres valores mayores por métrica.

CNN	Color	Exactitud validación	Exactitud testeo	Macro-F1	Precisión promedio	Recupero promedio
ResNet-50	RGB	0,9954	0,9324	0,9239	0,9374	0,9156
ResNet-50	grises	0,9857	0,9173	0,9202	0,9257	0,9200
DenseNet-121	RGB	0,9962	0,9324	0,9228	0,9401	0,9138
DenseNet-121	grises	0,9844	0,9234	0,9244	0,9276	0,9259
EfficientNet	RGB	0,9923	0,9105	0,9113	0,9248	0,9044
EfficientNet	grises	0,9829	0,9052	0,9051	0,9127	0,9044
MobileNet-V3	RGB	0,9949	0,9137	0,8967	0,9226	0,8822
MobileNet-V3	grises	0,9836	0,9032	0,9061	0,9105	0,9100




Fig. 3. Curvas de aprendizaje de la CNN DenseNet-121 con imágenes RGB.

Las matrices de confusión normalizadas obtenidas a partir del conjunto de testeo revelan que la dificultad de clasificación varía sustancialmente entre especies (Fig. 4, se muestra una de ocho disponibles). Las especies que mejor fueron clasificadas correctamente fueron *Cirsium vulgare*, *Echium plantagineum*, *Lotus* sp., *Scutia buxifolia* y *Solidago chilensis*. Todas tuvieron una precisión y una tasa de recupero en promedio igual o mayor al 0,90 para todas las combinaciones de modelos (Fig. 5). Las demás especies presentaron notable disparidad entre la precisión y la tasa de recupero. Por ejemplo, *Helianthus annuus* presentó una precisión promedio de 0,96 y una tasa de recupero promedio de 0,80. Esto indica que estas redes, en promedio, producen pocos falsos positivos para esta especie, pero dejan afuera una porción significativa de falsos negativos sin identificar. Por el contrario, *Acicarpha tribuloides* presenta una

precisión promedio de 0,80 y una tasa de recupero promedio de 0,96; indicando una baja tasa de falsos negativos y una alta incidencia de falsos positivos.

True \ Predicted	Cirsium	Helianthus	Solidago	Echium	Acicarpa	Lotus	Trifolium	Ligustrum	Scutia	Salix
Cirsium	0.98	0.01	—	—	—	0.00	—	—	0.00	—
Helianthus	0.09	0.76	0.06	0.00	—	—	0.01	0.06	0.01	0.02
Solidago	—	—	0.92	—	—	—	—	0.02	0.00	0.06
Echium	—	—	—	0.99	0.01	—	—	—	0.00	—
Acicarpa	—	—	—	0.00	1.00	—	—	—	—	—
Lotus	—	—	—	0.04	—	0.96	—	—	—	—
Trifolium	0.01	—	—	0.04	—	—	0.73	0.22	0.01	—
Ligustrum	—	—	0.01	—	0.02	—	—	0.96	0.00	0.01
Scutia	—	—	—	—	—	0.00	—	—	0.99	0.01
Salix	—	—	0.03	0.00	0.00	—	—	0.05	0.06	0.85

Fig. 4. Matriz de confusión normalizada para las distintas categorías (especies) obtenida con DenseNet-121 con imágenes RGB. En la diagonal se visualizan las tasas de recupero para cada especie.

La baja tasa de recupero de *H. annuus* se concentró en falsos negativos etiquetados erróneamente como *S. chilensis*, especies pertenecientes a la misma familia, morfológicamente con contorno circular y espinas, y con *L. lucidum* (ver, por ejemplo, Fig. 4). En el caso de la baja tasa de recupero de *T. pratense*, los falsos negativos fueron confusiones mayoritariamente con *L. lucidum* y *E. plantagineum*. En cambio, la baja precisión de *A. tribuloides* se debió principalmente a falsos positivos que dependían principalmente del color utilizado en el modelo: en RGB predominaron los falsos positivos de *L. lucidum*; en escala de grises los de *Salix* sp. También en la clasificación de *Salix* sp. se observó un efecto muy notorio del color. Por ejemplo, casi no hay falsos negativos de esta especie clasificados como *A. tribuloides* en RGB, mientras que en escala de grises estos son predominantes; en escala de grises los falsos positivos capturados provienen principalmente de *E. plantagineum* mientras que en RGB son casi inexistentes.




Fig. 5. Métricas por especie entre las 8 combinaciones de modelo y color en los experimentos multicategorías. Se informa el promedio y el rango de valores.

Los experimentos de clasificación binaria demostraron mejores métricas en promedio que los de clasificación global, salvo en la tasa de recupero de *E. plantagineum* y *H. annuus* (Fig. 6). También se encontró un menor rango de dispersión de las métricas de las clasificaciones binarias en comparación con sus contrapartes globales (Fig. 6). En general, las diferencias obtenidas obedecen más a las especies en cuestión que al modelo utilizado. *Echium plantagineum*, *Lotus sp.* y *S. buxifolia* obtuvieron todas métricas superiores a 0,92; mientras que *H. annuus* y *T. pratense* presentaron tasas de recupero entre 0,75 y 0,92.




Fig. 6. Comparación de métricas por especie entre las clasificaciones binarias (líneas punteadas) por especie y las clasificaciones multicategorías (líneas continuas). Se informa el promedio y el rango de valores.

4. Discusiones

Todas las CNN estudiadas alcanzaron exactitudes de test superiores 0,90 en la tarea de clasificación de imágenes de polen del conjunto de las 10 las diez especies (Tabla 3), demostrando la viabilidad de la identificación automática de polen a partir de imágenes de microscopía de bajo aumento y adquisición accesible con equipamiento convencional. Las curvas de entrenamiento de los experimentos junto a sus exactitudes de validación y testeo resultantes (Fig. 3, Tabla 3) indican que los modelos no presentaron sobreajustes y generalizaron adecuadamente frente a imágenes de muestras no utilizadas en su entrenamiento (Olsson et al., 2021).

De las cuatro redes analizadas, se destacaron DenseNet-121 y ResNet-50 con una performance equivalente. Las combinaciones de CNN con imágenes RGB para clasificar estas 10 especies superaron consistentemente en exactitud a sus contrapartes que utilizaron imágenes en escala de grises (Tabla 3). Sin embargo, esto no fue así en las métricas de las clasificaciones binarias donde no hubo una tendencia consistente de acuerdo al tipo de imagen utilizado (datos no mostrados). Los resultados obtenidos por Shammah et al. (2025) utilizando la CNN ResNet18 (no evaluada aquí) y un ensamble de 10 especies diferentes con imágenes de calidad comparable mostraron mejores métricas con el uso de escala de grises que con RGB. A su vez, se encontró para algunas especies (por ejemplo, *A. tribuloides* y *Salix* sp.) que las categorías que albergaban falsos positivos o falsos negativos cambiaba notablemente según el tipo de imágenes utilizadas. Esto sugiere que, en determinados casos, la información cromática puede aportar características discriminativas que complementan las señales morfológicas de forma; particularmente para clases con formas de grano similares pero características de tinción distintas. Por lo tanto, es necesario evaluar la performance de las redes en ambas modalidades con el conjunto de especies de interés antes de adoptar una arquitectura final.

El agrupamiento de 9 especies en una única categoría para obtener una clasificación binaria frente a una especie de interés redundante en una mejora de las métricas de todos los modelos (Fig. 6); en particular, en la precisión, no necesariamente en la tasa de recupero. Esto es esperable porque el proceso clasificatorio adquiere menos opciones de equivocación.

La legislación nacional Argentina establece que una muestra de miel puede ser etiquetada como monofloral si al menos el 45% de los granos de polen analizados son de la especie en cuestión. Este es el caso para el girasol (*H. annuus*), la flor violeta (*E. plantagineum*) y los tréboles (*T. pratense* y *Lotus* sp.) incluidos en este estudio. Hay excepciones a este valor umbral como lo son el 20% para mieles de *Citrus* o un 70% para mieles de *Eucalyptus*, entre otras. Las tasas de precisión y de recupero aquí obtenidas para cada especie, tanto en clasificaciones multicategoría como binarias, indican que la implementación de CNNs dedicadas a este rol específico son una tecnología promisorio y accesible para el auxilio del análisis melisopalinológico y la fiscalización y agregado de valor de mieles nacionales. Para ello es necesario incluir más especies de importancia apícola y económica en futuros análisis e implementar el procedimiento en muestras de miel reales con mecanismos de validación adecuados.

Agradecimientos

Queremos agradecer a dos revisores anónimos por sus valiosos comentarios y críticas sobre la versión preliminar de este manuscrito. Este trabajo fue financiado por la Universidad Nacional de Entre Ríos [PID-9185] y por la Fundación Ciencias Exactas y Naturales [convocatoria +4i].

Bibliografía

- Apablaza, O., Basilio, A. M., Ciappini, M. C., Fagúndez, G. A., Gaggiotti, M. D. C., Gutiérrez, A., Salgado Laurenti, C. R., & Winter, J. (2019). Guía para la caracterización de mieles argentinas. Ministerio de Agricultura, Ganadería y Pesca; INTA PROAPI. ISBN 978-987-47099-2-9.
- BM, Banco Mundial. (2024). Natural honey exports by country in 2024 [Data set]. Recuperado el 16 de abril de 2026 de <https://wits.worldbank.org/trade/comtrade/en/country/ALL/year/2024/tradeflow/Exports/partner/WLD/product/040900>
- Bradski, G. (2000). The OpenCV Library. Dr. Dobb's Journal of Software Tools.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. arXiv preprint arXiv:2008.05756.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L.-C., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Adam, H., & Le, Q. (2019). Searching for MobileNetV3. Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 4700–4708. <https://doi.org/10.1109/CVPR.2017.243>
- Jones, G. D., & Bryant, V. M. (2014). Pollen studies of East Texas honey. Palynology, 38(2), 242–258.
- MAGyP, Ministerio de Agricultura, Ganadería y Pesca. (2023). Argentina y el mercado mundial de productos apícolas. Recuperado el 16 de abril de 2026 de https://magyp.gob.ar/apicultura/mercado_mundial.php
- 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>
- SADA, Sociedad Argentina de Apicultores. (2026). Apicultura en Argentina. Congreso SADA. Recuperado el 16 de abril de 2026 de <https://congresosada.com/apicultura-en-argentina/>
- Shammah, J., Buemi, M. E., & Sanguinetti, A. (2025). Clasificación automática de tipos polínicos apícolas. JAIIO, Jornadas Argentinas De Informática, 11(11), 26-37.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. International Conference on Machine Learning (ICML), 6105–6114. <https://doi.org/10.48550/arxiv.1905.11946>
- Tobler, A. S., & Basilio, A. M. (2023). La oferta de miel a los consumidores: el caso de la ciudad de Zárate (Buenos Aires, Argentina). EUNK Revista Científica de Abejas y Apicultores, 2(1), 19–27. <https://doi.org/10.52559/eunk.v2i1.33>

- Valiente, J. M., Juan-Borrás, M., López-García, F., & Escriche, I. (2023). Automatic pollen recognition using convolutional neural networks: The case of the main pollens present in Spanish citrus and rosemary honey. *Journal of Food Composition and Analysis*, 123, 105605. <https://doi.org/10.1016/j.jfca.2023.105605>
- Viertel, P., König, M. (2022). Pattern recognition methodologies for pollen grain image classification: a survey. *Machine Vision and Applications* 33, 18. <https://doi.org/10.1007/s00138-021-01271>.
- Zarlavsky, G. E. (2014). *Histología Vegetal: técnicas simples y complejas*. Sociedad Argentina de Botánica, Buenos Aires, 198.