

Hacia la estimación basada en aprendizaje automático de distribución de tamaño de cristales y morfología de plagioclasa: un ejemplo práctico en el Campo Volcánico Payún

Matrú, Argentina

CHIAACCHIERA, Sabina ^{1,3(*)}, PEDRAZA DE MARCHI, Ana Carolina ^{2,3,4(*)}

1. Instituto de Recursos Minerales, Facultad de Ciencias Naturales y Museo, Universidad Nacional de La Plata. Argentina. Calle 64 e/ 120 y 121, La Plata (1900), Buenos Aires, Argentina.
2. Centro de Investigaciones Geológicas (CONICET-UNLP), 1 No. 644, B1900TAC, La Plata, Argentina.
3. Consejo Nacional de Investigaciones Científicas y Técnicas (Conicet), Argentina. Godoy Cruz 2290 (C1425FQB), CABA, Argentina.
4. Facultad de Ciencias Astronómicas y Geofísicas, Universidad Nacional de La Plata. Argentina. Paseo del Bosque S/N, La Plata (1900), Buenos Aires,

sabina.chiacchiera@gmail.com, cpedrazadm@cig.museo.unlp.edu.ar

RESUMEN

La caracterización textural de minerales en secciones delgadas de rocas volcánicas permite conocer la distribución del tamaño de los cristales (*crystal size distribution*, CSD). El estudio de esta distribución provee información sobre la evolución térmica y dinámica del magma, así como sobre los procesos de nucleación y crecimiento, las tasas de enfriamiento y los tiempos de residencia. El análisis clásico se basa en representaciones logarítmicas de la distribución en función del tamaño de los cristales y posibilita identificar pendientes y curvaturas sensibles a estos procesos magmáticos. Sin embargo, la obtención manual de estas curvas requiere un trabajo exhaustivo, lo que limita su eficiencia. En este contexto, los métodos de aprendizaje

automático, en particular de aprendizaje profundo (*deep learning*, DL), ofrecen una alternativa para automatizar la detección y caracterización del tamaño de los cristales en secciones delgadas. En este trabajo se presenta un modelo de DL que detecta y clasifica fenocristales de plagioclasa en rocas volcánicas porfíricas donde este mineral es el componente principal. El modelo genera curvas CSD de manera automática y semiautomática, reduciendo los tiempos de procesamiento y manteniendo la fidelidad morfométrica. Como aplicación preliminar, el modelo se implementó en muestras del Campo Volcánico Payún Matrú, ubicado en la provincia basáltica de trasarco de Payenia, en el centro-oeste de Argentina. Los resultados muestran un desempeño coherente con curvas CSD obtenidas mediante procedimientos manuales, destacando el potencial del método como herramienta complementaria para estudios texturales en sistemas magmáticos.

Palabras clave: aprendizaje automático, plagioclasa, distribución del tamaño de los cristales, morfometría cristalina

Towards machine learning-driven estimation of crystal size distribution and morphology in plagioclase: a practical example from the Payún Matrú Volcanic Field, Argentina.

The textural characterization of minerals in thin sections of volcanic rocks allows the determination of the crystal size distribution (CSD). The study of this distribution provides information on the thermal and dynamic evolution of magma, as well as on nucleation and growth processes, cooling rates, and residence times. The classical analysis is based on logarithmic representations of the distribution as a function of crystal size and allows the recognition of slopes and curvatures sensitive to these magmatic processes. However, the manual obtention of these curves requires exhaustive work, limiting its analytical efficiency. In this context, machine learning methods, particularly deep learning (DL), offer an alternative to

automatize the detection and characterization of crystal size in thin sections. This study presents a DL model that detects and classifies plagioclase phenocrysts in porphyritic volcanic rocks where this mineral is the main component. The model generates CSD curves automatically and semi-automatically, reducing processing times while preserving morphometric fidelity. As a preliminary application, the model was implemented on samples from the Payún Matrú Volcanic Field, located in the back-arc basaltic province of Payenia, west-central Argentina. Results show model performance consistent with CSD curves obtained manually and highlight the potential of the method as a complementary tool for textural studies in magmatic systems.

Keywords: machine learning, plagioclase, crystal size distribution, crystal morphometry

1. INTRODUCCIÓN

La inteligencia artificial (IA), y en particular el aprendizaje automático (*machine learning*, ML), ha transformado múltiples áreas científicas al permitir la detección automática de patrones complejos en grandes volúmenes de datos (*e.g.*, Hastie *et al.*, 2009; Jordan y Mitchell, 2015). Estas herramientas impulsaron el procesamiento del lenguaje natural (Vaswani *et al.*, 2017), el diagnóstico médico (Bejnordi *et al.*, 2017) y los sistemas autónomos (Chen *et al.*, 2015). Dentro de las tareas de uso más extendido en el campo del ML se encuentran la clasificación y la regresión (Murphy, 2012). La clasificación asigna una etiqueta a una imagen o a un objeto, pero no delimita sus bordes. Debido a que muchas aplicaciones requieren también de una delimitación precisa, se desarrolló la segmentación semántica, técnica que asigna a cada píxel una clase específica. El aprendizaje profundo (*deep learning*, DL) mejoró las técnicas de segmentación mediante redes neuronales convolucionales. Estas estructuras recuperan detalles espaciales de alta resolución, posibilitando la delimitación de objetos con una mayor precisión (Long *et al.*, 2015; Ronneberger *et al.*, 2015; Goodfellow *et al.*, 2016). En este contexto, la

segmentación semántica multiclase (*multiclass semantic segmentation*, MSS) extiende este enfoque al permitir la identificación simultánea de múltiples categorías dentro de una misma imagen. Esta técnica se ha utilizado en distintas especialidades, desde el análisis de escenas urbanas (He *et al.*, 2015; Save, 2020) hasta los sistemas de conducción autónoma (Papadeas *et al.*, 2021), mientras que en geociencias se usó para segmentar imágenes de tomografía de microscopía de rayos X (Martí-Isasi, 2023), para detectar granos minerales de forma automática (Latif *et al.*, 2022) y para caracterizar la morfometría de cristales en rocas ígneas (Tóth y MacLennan, 2024).

El feldespato plagioclasa es uno de los minerales más abundantes de la corteza terrestre (*e.g.*, Smith y Brown, 1988) y constituye un indicador sensible de la evolución magmática. Sus características texturales, tales como forma, tamaño y distribución espacial, registran las condiciones de nucleación y crecimiento, lo cual permite inferir escalas temporales de cristalización (Cashman, 1993; Higgins, 1996; Holness, 2014). Para cuantificar esta información, el análisis clásico se basa en curvas de distribución del tamaño de los cristales (*crystal size distribution*, CSD; Cashman y Marsh, 1988; Higgins, 2000). En estas curvas se grafica el logaritmo natural de la densidad de población cristalina ($\ln(n(L))$) versus la longitud característica del cristal (L). La densidad de población se obtiene al calcular el número de cristales por unidad de volumen dentro de un intervalo de tamaño, mientras que la longitud característica corresponde por lo general a su dimensión mayor. En este gráfico, la pendiente y la curvatura de la curva son sensibles a procesos magmáticos como la nucleación, el crecimiento y la remoción de cristales (*e.g.*, Marsh, 1988; Higgins, 2000; Armienti, 2008). En sistemas magmáticos próximos al estado estacionario, las curvas CSD ideales presentan relaciones lineales en escala semilogarítmica, donde la pendiente de la recta se vincula con las tasas relativas de nucleación y crecimiento y, por lo tanto, con la historia cinética de cristalización de la roca (*e.g.*, Marsh, 1988; Higgins, 2002). Una desviación significativa de la

linealidad se manifiesta como curvas o *kinks* e indica procesos magmáticos más complejos, como cambios en las tasas de nucleación y crecimiento, enfriamiento no uniforme, mezcla de eventos de cristalización o maduración textural (*e.g.*, Higgins, 2000; Cashman, 2020). Esta capacidad de extraer información cinética de relevancia mediante el análisis textural y espacial de cristales convierte a las CSD en una herramienta cuantitativa valiosa (Fornaciai *et al.*, 2015; Bell *et al.*, 2020; Cashman, 2020).

La obtención de curvas CSD requiere identificar y medir manualmente cientos de cristales en secciones delgadas. Ese procedimiento es laborioso y limita la aplicación sistemática del método (Neave *et al.*, 2017; Toth y MacLennan, 2024). A esta limitante se suma que los tamaños medidos en sección delgada son aparentes, porque el corte bidimensional rara vez atraviesa el cristal por su dimensión mayor. La corrección estereológica convierte esas medidas en una distribución tridimensional de tamaños y compensa el sesgo del plano de corte y el de la probabilidad de intersección. Su aplicación exige asumir la fábrica de la roca y la forma de los cristales, definida por sus relaciones axiales y su redondeamiento (Higgins, 2000). Como alternativa, los diagramas de relación de aspecto (RA) en función de la raíz cuadrada del área ($\sqrt{A}$) permiten comparar poblaciones cristalinas sin introducir sesgos estereológicos (Neave *et al.*, 2014). En este caso, RA se define como el cociente entre la longitud mayor (largo) y la longitud menor (ancho) del cristal, calculado a partir de mediciones bidimensionales.

La segmentación automática de cristales ofrece una alternativa al conteo manual. Emplea modelos de aprendizaje supervisado que requieren imágenes previamente etiquetadas, es decir, imágenes en las que los cristales fueron identificados y delimitados. El etiquetado manual es la parte más laboriosa del proceso y herramientas como *Segment Anything Model* (SAM; Kirillov *et al.*, 2023) permiten acelerarlo. Sobre esa base se desarrolló ACSD2D (*Automatic Crystal Size Distribution 2D*), un flujo de trabajo que automatiza la detección de cristales de plagioclasa en imágenes petrográficas y genera curvas CSD aproximadas y

diagramas RA- $\sqrt{A}$ del tipo propuesto por Neave *et al.* (2014). ACSD2D no incorpora corrección estereológica, por lo que las curvas CSD del caso de estudio se calcularon *a posteriori* con *CSDCorrections* (Higgins, 2000).

Este estudio presenta el flujo de trabajo de ACSD2D y su validación externa sobre muestras del Campo Volcánico Payún Matrú (CVPM), en el centro-oeste de Argentina. El objetivo es determinar si una segmentación rápida y aproximada conserva la fidelidad morfológica necesaria para acelerar el análisis textural en sistemas magmáticos.

2. METODOLOGÍA

2.1 Adquisición y etiquetado de las imágenes

Las fotomicrografías empleadas para entrenar el modelo se adquirieron con un microscopio Olympus BX53 equipado con una cámara digital Olympus UC30 y con el software *Olympus Stream Start*. Se obtuvieron imágenes a nicols cruzados en formato .jpg de 26 secciones delgadas procedentes de colecciones académicas y de material inédito de distintos sectores del arco y el retroarco andino argentino (Cátedra de Petrología I, Facultad de Ciencias Naturales y Museo, Universidad Nacional de La Plata; Hernando, 2012). Las rocas volcánicas seleccionadas se componen únicamente de fenocristales de plagioclasa acompañados por minerales ferromagnesianos fácilmente distinguibles, principalmente olivino y piroxeno, y en menor proporción anfíbol y biotita. Las muestras de Hernando (2012) incluidas en el entrenamiento no son las mismas que se utilizaron como caso de estudio.

El etiquetado de cristales se realizó de manera semiautomática y combinó segmentación asistida con anotación manual. La segmentación se realizó con SAM; la anotación y edición de las máscaras con Segment Anything Annotator (SAA). Esta interfaz, desarrollada en Python, integra SAM con *Labelme*, una herramienta de anotación de imágenes que permite dibujar, editar y corregir polígonos de forma interactiva (He, 2023). Todas las máscaras automáticas se

revisaron visualmente y corrigieron a mano cuando el polígono no cubría la totalidad del cristal o bien abarcaba más de uno. Estas discrepancias se debieron a las texturas internas de los cristales (*e.g.*, zonación, maclado), a las variaciones de contraste por extinción cristalina, o a los contactos entre individuos de un mismo glomérulo cristalino. De manera adicional, se incorporaron dos modificaciones al código original de SAA: (1) un algoritmo que asigna a cada polígono una clase de tamaño a partir de su eje mayor L (distancia euclídea máxima entre vértices) y (2) la exportación de etiquetas en formato .jpg con fondo blanco y polígonos coloreados según la clase asignada. Se definieron cuatro clases de tamaño para generar las imágenes etiquetadas, cada una con un color asignado: amarillo para $L \leq 0,5$ mm (76 a 150 píxeles), verde para $0,5 < L \leq 0,75$ mm (151 a 225 píxeles), celeste para $0,75 < L \leq 1$ mm (226 a 300 píxeles) y violeta para $L > 1$ mm (más de 300 píxeles). Los polígonos de menos de 76 píxeles no se etiquetaron, de modo que la primera clase tiene un límite inferior de detección. Para evitar inconsistencias derivadas de los códigos RGB en imágenes .jpg, se aplicó el algoritmo de agrupamiento *k-means* (Lloyd, 1982; Arthur y Vassilvitskii, 2006), el cual homogeneizó los colores y asignó cada fenocristal a una única clase de tamaño en las imágenes exportadas en formato .png. Este procedimiento produjo 412 imágenes con sus etiquetas asociadas.

2.2 División del conjunto de datos

Las 412 imágenes etiquetadas se agruparon en tres subconjuntos mutuamente excluyentes: entrenamiento (E, 320 imágenes), prueba (P, 81 imágenes) y validación (V, 11 imágenes). El subconjunto E se utilizó para ajustar los parámetros del modelo, el subconjunto P sirvió para seleccionar los hiperparámetros a partir del desempeño registrado durante el entrenamiento, y el subconjunto V se reservó para la evaluación final sobre imágenes que no intervinieron en el ajuste de los parámetros. Las imágenes del subconjunto V se etiquetaron de acuerdo con el mismo protocolo del apartado 2.1, aplicando idénticos criterios petrográficos y

de clasificación por tamaño. Esa consistencia permitió comparar la segmentación manual con la automática.

2.3 Segmentación semántica multiclase

Los programas numéricos se implementaron en *Python* utilizando *Jupyter Notebook*, un entorno interactivo que facilita la programación, ejecución y visualización de resultados. El modelo se orientó exclusivamente a la segmentación semántica multiclase del tamaño de los cristales, por lo que no incorporó módulos de clasificación litológica ni de interpretación textural. Los parámetros aprendibles del modelo correspondieron a los pesos y sesgos de las capas convolucionales 2D de la arquitectura. El entrenamiento se realizó utilizando el optimizador Adam (Kingma y Ba, 2015), mediante un procedimiento empírico de ajuste de hiperparámetros basado en la evaluación del desempeño del modelo mediante métricas estándar de segmentación (Csurka *et al.*, 2013; Haque y Neubert, 2020). Entre los hiperparámetros explorados se incluyeron: la tasa de aprendizaje (*learning rate*, lr), el tamaño del lote (*batch size*), el número de épocas, la arquitectura de la red (número de capas y filtros), la normalización por lotes (*batch normalization*), la tasa de dilatación y los parámetros de regularización. El tamaño del lote corresponde al número de imágenes procesadas en cada iteración antes de actualizar los pesos del modelo. Una época se define como el recorrido completo por el subconjunto de entrenamiento. La normalización por lotes es una técnica que ajusta y escala las activaciones internas de la red para favorecer la estabilidad durante el entrenamiento. La tasa de dilatación controla el espaciamiento entre los elementos del filtro convolucional, permitiendo ampliar el campo receptivo sin aumentar el número de parámetros.

Los parámetros de regularización son técnicas que ayudan a evitar que el modelo se ajuste en exceso a los datos de entrenamiento, efecto conocido como sobreajuste (*overfitting*). Es deseable evitar el sobreajuste, ya que limita la capacidad de generalización del modelo y,

por lo tanto, su habilidad para realizar predicciones adecuadas sobre datos no vistos. La selección final de hiperparámetros se realizó a partir del análisis comparativo del rendimiento del modelo, priorizando la estabilidad del entrenamiento, la convergencia de la función de pérdida (*loss*) y la mejora de las métricas de segmentación. Este enfoque se alinea con las recomendaciones metodológicas para la optimización de modelos de DL (Burkov, 2019; Chollet, 2021).

Para realizar la segmentación de imágenes, se empleó una red neuronal U-Net configurable (Ronneberger *et al.*, 2015), con entradas de $256 \times 256 \times 3$ píxeles y salida de cinco clases (el fondo y las cuatro clases de tamaño) (Fig. 1). La arquitectura U-Net consta de tres etapas principales: codificación (*encoder*), cuello de botella (*bottleneck*) y decodificación (*decoder*). La etapa de codificación comprende tres bloques convolucionales con un número creciente de filtros (16, 24 y 32, respectivamente). Cada bloque está compuesto por dos convoluciones 3×3 , con función de activación ReLU, *padding* = “same”, tasa de dilatación configurable y *Batch Normalization* opcional. Cada bloque es seguido por una operación *MaxPooling* 2×2 , mediante la cual la resolución espacial se reduce progresivamente de 256×256 a 128×128 , 64×64 y, finalmente, 32×32 píxeles. El cuello de botella opera sobre una representación de 32×32 píxeles y consta de dos convoluciones 3×3 con 64 filtros. Estas convoluciones mantienen la misma configuración empleada en los bloques de codificación. La etapa de decodificación, por su parte, comprende tres bloques con un número decreciente de filtros (32, 24 y 16, respectivamente). Cada bloque comienza con una operación *UpSampling* 2×2 , que duplica la resolución espacial. La representación resultante se concatena con las características correspondientes de la etapa de codificación mediante *skip connections*. A continuación, se aplican dos convoluciones 3×3 con activación ReLU, *padding* = “same”, tasa de dilatación configurable y *Batch Normalization* opcional. De este modo, la resolución espacial se recupera. Finalmente, una capa convolucional 1×1 , seguida de una función de

activación *softmax*, genera la predicción multiclase para cada píxel. La salida de la red consiste en un mapa de segmentación de 256×256 píxeles, en el que cada píxel es asignado a una de las cinco clases consideradas. A partir de este mapa de segmentación se obtienen los contornos de los cristales, que constituyen la base para el cálculo de los parámetros morfométricos.

Para evaluar el desempeño de la segmentación y la capacidad del modelo para discriminar correctamente las distintas clases, se construyó una matriz de confusión, la cual resume los verdaderos positivos (*True Positive*, TP), falsos positivos (*False Positive*, FP), falsos negativos (*False Negative*, FN) y verdaderos negativos (*True Negative*, TN). A partir de esta matriz se evaluó el desempeño del modelo de segmentación para cada clase mediante métricas como la precisión, la exactitud, el *recall*, el *F1-Score*, el *Intersection-over-Union* (IoU), el coeficiente Dice y la precisión promedio (*mean average precision*, mAP) (Tabla 1).

Arquitectura U-Net

Red convolucional para segmentación semántica de imágenes




FIG. 1. Esquema de la arquitectura U-Net utilizada en este estudio. Los nombres de los componentes se presentan en inglés, siguiendo la nomenclatura estándar de la literatura especializada. La arquitectura procesa imágenes de entrada de $256 \times 256 \times 3$ píxeles y genera mapas de segmentación de $256 \times 256 \times 5$ clases mediante un procedimiento de *encoder*, *bottleneck* y *decoder*. Cada bloque *encoder/decoder* contiene dos capas convolucionales (Conv) con normalización por lotes (BN). En el diagrama, el *MaxPooling* reduce el tamaño del mapa, mientras que el *UpSampling* lo agranda. Las líneas naranjas discontinuas muestran las *skip connections* que concatenan características entre niveles equivalentes del *encoder* y del *decoder*.

Tabla 1. Métricas obtenidas para la evaluación del rendimiento de los modelos.

Métrica	Fórmula	Descripción y observaciones
Exactitud global (Acc)	$\frac{TP + TN}{TP + TN + FP + FN}$	Porcentaje de píxeles clasificados correctamente. Sensible a clases dominantes, e.g., “el fondo” (Csurka <i>et al.</i> , 2013; Haque y Neubert, 2020).
Exactitud media por clase (mAcc)	$\frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FN_i}$	Promedio de la exactitud calculada individualmente para cada clase. Mitiga el sesgo de clases dominantes (Csurka <i>et al.</i> , 2013).
Precisión (P)	$\frac{TP}{TP + FP}$	Proporción de píxeles segmentados como clase ‘i’ que realmente pertenecen a la clase ‘i’, o bien la proporción de predicciones positivas que son correctas. Métrica sensible a la sobresegmentación (Powers, 2011; Minaee <i>et al.</i> , 2021).
Recall (R)	$\frac{TP}{TP + FN}$	Proporción de píxeles verdaderos de la clase ‘i’ que fueron correctamente identificados. Métrica sensible a la subsegmentación.
F1-Score (F1)	$\frac{2 \times P \times R}{P + R}$	Media armónica entre Precisión y Recall para una clase. Evalúa el balance entre exactitud (proporción de predicciones positivas correctas) y cobertura (proporción de casos positivos reales que se detectan), cuantificando aciertos de clasificación (Powers, 2011; Minaee <i>et al.</i> , 2021).
F1-Score promedio (mF1)	$\frac{1}{N} \sum_{i=1}^N F1_i$	Promedio del F1-Score de todas las clases. Buena métrica general para desbalance de clases (Powers, 2011; Minaee <i>et al.</i> , 2021).
Intersection-over-Union (IoU)	$\frac{TP}{TP + FP + FN}$	Mide la superposición entre la predicción y el valor real para una clase específica, calculando el área de intersección dividida por el área de unión. También se conoce como Índice de Jaccard. Valores cercanos a 1 indican que la predicción coincide muy bien con el área real de la clase, mientras que valores bajos indican discrepancias, cuantificando aciertos espaciales (Jaccard, 1912; Rahman y Wang, 2016).
IoU promedio (mIoU)	$\frac{1}{N} \sum_{i=1}^N IoU_i$	Promedio del IoU de todas las clases. Ofrece una medida global de precisión espacial (Long <i>et al.</i> , 2015; Minaee <i>et al.</i> , 2021).
Media de la precisión promedio (mAP)	$\frac{1}{N} \sum_{i=1}^N AP_i$	Para cada clase, se calcula la precisión promedio (AP) como el área bajo la curva Precision-Recall. El mAP se define como el promedio de las precisiones promedio de todas las clases. Esta métrica permite capturar tanto la calidad de las predicciones positivas como la capacidad del modelo para recuperarlas (Everingham <i>et al.</i> , 2010).
Coefficiente Dice (Dice)	$\frac{2 \times TP}{2 \times TP + FP + FN}$	Similar al F1-Score. Es una medida de la similitud entre las segmentaciones predicha y real. Es particularmente sensible a los falsos negativos y a la coincidencia de los bordes (Dice, 1945; Csurka <i>et al.</i> , 2013; Milletari <i>et al.</i> , 2016).
Dice promedio (mDice)	$\frac{1}{N} \sum_{i=1}^N Dice_i$	Promedio del coeficiente Dice de todas las clases. Popular en aplicaciones de medicina (Milletari <i>et al.</i> , 2016; Reinke <i>et al.</i> , 2021).

2.4 Construcción de curvas CSD y diagramas RA- $\sqrt{A}$

Una vez entrenado el modelo, rutinas independientes aplicadas a las máscaras segmentadas permiten calcular los parámetros geométricos (área, eje mayor y relación de aspecto) y construir las curvas CSD y los diagramas RA- $\sqrt{A}$. Estas rutinas proveen una aproximación a la clásica CSD a partir de la detección de cristales individuales por segmentación por color. La densidad de cristales se calcula con la Ecuación 1, donde $n(L_i)$ representa la densidad de cristales en el *bin* 'i' (#cristales/mm), N_i refiere al número de cristales en el *bin* 'i', y ΔL_i indica el ancho del *bin* 'i' (mm). Se emplea el logaritmo natural para obtener una escala logarítmica y facilitar la representación gráfica.

$$\ln(n(L_i)) \approx \ln\left(\frac{N_i}{\Delta L_i}\right) \quad (1)$$

La Ecuación 1 no constituye un cálculo físico riguroso porque no incorpora la conversión de datos de 2D a 3D habitual en curvas CSD. Aun así, refleja tendencias relativas en la distribución de tamaños y permite comparar distintos conjuntos de cristales. Para caracterizar el tamaño se empleó $\sqrt{A}$ como métrica representativa. Neave *et al.* (2014, 2017) demostraron que el uso de $\sqrt{A}$ reduce el efecto de la morfología de los cristales en las CSD no corregidas estereológicamente. El diagrama RA- $\sqrt{A}$ distingue los cristales elongados de los equidimensionales con longitud máxima similar y evita los errores de interpretación textural que introduce una corrección 3D inapropiada. Esta métrica también se validó para comparar distribuciones generadas de manera automática (Toth y MacLennan, 2024).

3. RESULTADOS

3.1 Estadística de los datos del modelo

Los cristales de las imágenes analizadas se agruparon en cuatro clases de tamaño (ver sección 2.1). En total se etiquetaron 7.048 cristales. La clase más frecuente es $L \leq 0,5$ mm (4.100

instancias), seguida por $0,5 < L \leq 0,75$ mm (1.419 instancias), $L > 1$ mm (862 instancias) y $0,75 < L \leq 1$ mm (667 instancias). La tabla 2 resume la cantidad de instancias por clase y su distribución en cada subconjunto, mientras que la figura 2 permite evaluar el equilibrio en términos de abundancia relativa para cada clase y para cada subconjunto. A pesar de las diferencias numéricas entre clases, la distribución relativa varía poco entre los subconjuntos: 58-60% para $L \leq 0,5$ mm, 20-23% para $0,5 < L \leq 0,75$ mm, 7-10% para $0,75 < L \leq 1$ mm y 9-13% para $L > 1$ mm. Si bien el desbalance entre clases es marcado, este se repite para los tres subconjuntos. Esta homogeneidad indica que la partición no introdujo sesgos adicionales, aunque no logra corregir el desbalance original.




FIG. 2. Conteo total de cristales. **A.** Subconjunto de entrenamiento (E). **B.** Subconjunto de prueba (P). **C.** Subconjunto de validación (V).

Tabla 2. Estadística de los datos para los subconjuntos de entrenamiento (E), prueba (P) y validación (V).

Tamaños	E	P	V
$L \leq 0,5$ mm	3.448 (58,06%)	483 (58,33%)	169 (60,14%)
$0,5 < L \leq 0,75$ mm	1.171 (19,72%)	190 (22,95%)	58 (20,64%)
$0,75 < L \leq 1$ mm	567 (9,55%)	79 (9,54%)	21 (7,47%)
$L > 1$ mm	753 (12,68%)	76 (9,18%)	33 (11,74%)

3.2 Evaluación del modelo

El rendimiento de los modelos de aprendizaje automático depende tanto de la calidad de los datos como de la configuración de los hiperparámetros del modelo, lo cual puede evaluarse con métricas estándar (Tabla 1). Para esto, se deben evitar situaciones de sobresegmentación y

subsegmentación. La sobresegmentación se produce cuando el modelo divide un cristal incorrectamente en diferentes cristales menores o cuando el cristal predicho excede los límites reales del cristal. La subsegmentación ocurre cuando el modelo no captura completamente el tamaño del cristal y omite parte de su estructura espacial debido a la incapacidad para identificar detalles pequeños. Esto último también puede originarse en la pérdida de resolución de las etapas de procesamiento, lo cual es común en objetos pequeños que, debido a su tamaño o a la ausencia de características distintivas, son los más afectados y llegan a omitirse por completo.

Se compararon tres tasas de aprendizaje (0,01, 0,001 y 0,0001) durante 100 épocas a partir de las curvas de exactitud y de pérdida de los subconjuntos de entrenamiento y de prueba (Fig. 3). La tasa de 0,001 dio el mejor desempeño general, con los valores más altos de IoU y de mAP. Esta configuración mostró también curvas de pérdida y de exactitud más estables, con convergencia más rápida y menor pérdida en el subconjunto de prueba. Las matrices de confusión (Fig. 4) permiten identificar los patrones sistemáticos de error asociados a las situaciones de sobresegmentación y subsegmentación.




FIG. 3. A, B. Curvas de pérdida y exactitud para el subconjunto de entrenamiento (E). C, D. Curvas de pérdida y exactitud para el subconjunto de prueba (P). E, F. Curvas de las métricas IoU y mAP obtenidas al evaluar diferentes valores de la tasa de aprendizaje para el subconjunto de prueba (P). La línea gruesa corresponde a la tasa elegida para el modelo (0,001). Las líneas punteadas indican las otras tasas evaluadas (0,01 y 0,0001), a efectos de comparación.




FIG. 4. Matrices de confusión normalizadas por clase verdadera. A. Subconjunto de entrenamiento (E). B. Subconjunto de prueba (P). C. Subconjunto de validación (V).

Las métricas por clase revelan un comportamiento diferencial según el tamaño de los cristales (Fig. 5; Tabla 3). Las clases extremas ($L \leq 0,5$ mm y $L > 1$ mm) presentan el desempeño más alto, mientras que las intermedias muestran mayor dispersión en las métricas. La clase $0,75 < L \leq 1$

mm registra la menor precisión, lo que sugiere una mayor proporción de falsos positivos asociados a la sobresegmentación. En el *recall*, la clase $L > 1$ mm alcanza los valores más altos, mientras que las clases intermedias concentran los más bajos en los subconjuntos de entrenamiento y validación. El *F1-Score* confirma ese patrón: es más alto en $L > 1$ mm, alto en $L \leq 0,5$ mm y menor en las clases intermedias.




FIG. 5. Gráfico de métricas por clase. **A.** Subconjunto de entrenamiento (E). **B.** Subconjunto de prueba (P). **C.** Subconjunto de validación (V). El eje horizontal agrupa las cuatro clases de tamaño, expresadas en milímetros: $L \leq 0.5$; $0.5 < L \leq 0.75$; $0.75 < L \leq 1$ y $L > 1$. El eje vertical representa el valor normalizado de cada métrica. Valores mayores indican un mejor desempeño del modelo. A: Accuracy. P: Precision. R: Recall. F1: F1-Score.

Tabla 3. Métricas de evaluación del modelo para los subconjuntos de entrenamiento (E), prueba (P) y validación (V) para cada clase. Los valores numéricos se normalizaron entre 0 y 1.

Conjunto/Métrica	$L \leq 0,5$ mm			$0,5 < L \leq 0,75$ mm			$0,75 < L \leq 1$ mm			$L > 1$ mm		
	E	P	V	E	P	V	E	P	V	E	P	V
Accuracy	0,95	0,70	0,85	0,87	0,83	0,58	0,77	0,80	0,56	0,99	0,99	0,99
Precision	0,97	0,94	0,92	0,93	0,86	0,77	0,89	0,77	0,69	0,98	0,99	0,97
Recall	0,95	0,70	0,85	0,87	0,83	0,58	0,77	0,80	0,56	0,99	0,99	0,99
<i>F1-Score</i>	0,96	0,80	0,88	0,9	0,84	0,66	0,82	0,79	0,62	0,99	0,99	0,98
IoU	0,93	0,67	0,79	0,82	0,73	0,49	0,70	0,65	0,45	0,98	0,98	0,96
Dice	0,96	0,80	0,88	0,9	0,84	0,66	0,83	0,79	0,62	0,99	0,99	0,98

Las métricas globales, por otra parte (Tabla 4), muestran una exactitud media elevada y relativamente estable entre subconjuntos. Esa estabilidad se explica por la alta proporción de píxeles de fondo y de las clases más representadas, que domina el cálculo de la exactitud en un conjunto desbalanceado. En contraste, las métricas basadas en superposición (mIoU, mDice) disminuyen de manera progresiva desde entrenamiento hasta validación. Esa caída refleja su mayor sensibilidad a los errores de delimitación y a las clases con menor representación relativa. La disminución es moderada y no se acompaña de un deterioro de la exactitud, lo que resulta compatible con un ajuste sin sobreajuste marcado.

Tabla 4. Métricas globales de evaluación del modelo para los subconjuntos de entrenamiento (E), prueba (P) y validación (V). Los valores de mAcc no incluyen la clase del “fondo”.

Conjunto/Métrica	E	P	V
mAcc	0,89	0,83	0,74
mIoU	0,86	0,76	0,67
mDice	0,92	0,86	0,79

3.3 Validación del modelo

Las curvas CSD y los diagramas $RA-\sqrt{A}$ obtenidos a partir del subconjunto de validación se muestran en la figura 6. Se observa que la segmentación automática reproduce la manual tanto en la identificación como en la delimitación de los cristales (Fig. 6B, C), de manera coherente

con los valores de desempeño del apartado anterior. El modelo detectó la mayoría de los cristales, incluso en imágenes complejas con glomérulos (Fig. 6A, panel A4) o con microlitos abundantes (Fig. 6A, paneles A2, A3, A5 y A6). Las discrepancias se limitaron a la subsegmentación de cristales de gran tamaño ($L > 1$ mm; violeta) y a la detección parcial de glomérulos. Esas diferencias no alteran de manera apreciable la forma general de las curvas CSD ni la distribución en los diagramas $RA-\sqrt{A}$ (Fig. 6D, E).

En las curvas CSD sin corrección estereológica (Fig. 6D), se utilizaron círculos para representar los datos del etiquetado manual y cruces para los obtenidos por el modelo. Las líneas continua y punteada son los ajustes de cada conjunto de puntos. Ambas curvas presentan pendiente negativa, curvatura comparable y una distribución continua de tamaños. La curva automática reproduce el comportamiento general de la manual y conserva los puntos de inflexión y los intervalos de mayor densidad de cristales. El diagrama $RA-\sqrt{A}$ (Fig. 6E) muestra la misma correspondencia entre ambas metodologías: cristales pequeños y numerosos con amplia dispersión de RA; cristales grandes y escasos con RA más acotada. Los puntos manuales y automáticos se superponen o quedan muy próximos, salvo donde los errores de segmentación subestiman o sobreestiman el número de cristales. Incluso en imágenes morfológicamente complejas (Fig. 6A, paneles A2 y A3), los resultados muestran una buena correspondencia entre ambas aproximaciones.




FIG. 6. Validación del modelo sobre seis imágenes del subconjunto de validación. Cada fila corresponde a una imagen y cada columna a un tipo de resultado. **A.** Fotomicrografía original de un área de la sección delgada a nicols cruzados. La barra blanca equivale a 1 mm. **B.** Etiquetado manual asistido con SAM. **C.** Segmentación automática obtenida con ACSD2D. **D.** Curva CSD aproximada (ecuación 1), sin corrección estereológica, a partir del etiquetado manual (círculos y línea continua celeste) y del modelo ACSD2D (cruces y línea punteada roja). **E.** Diagrama $RA-\sqrt{A}$ a partir del etiquetado manual (círculos) y del modelo ACSD2D (cruces). En los paneles B a E, los colores indican las clases de tamaño: $L \leq 0,5$ mm (amarillo), $0,5 < L \leq 0,75$ mm (verde), $0,75 < L \leq 1$ mm (celeste) y $L > 1$ mm (violeta).

3.4 Caso de estudio: Campo Volcánico Payún Matrú

El Campo Volcánico Payún Matrú (CVPM) forma parte de la provincia basáltica de Payenia, en el trasarco andino de la Zona Volcánica Sur, en el centro-oeste de Argentina (Polanski, 1954). Dentro de este campo se emplaza el volcán Payún Matrú ($36^{\circ}25' \text{ S}$, $69^{\circ}14' \text{ O}$), principal edificio del sistema y un volcán en escudo con una caldera cuaternaria en su cumbre. El diámetro basal es de 15 a 18 km y el de la caldera central 8 a 8,5 km (Hernando *et al.*, 2014, 2019). Dos campos basálticos flanquean el edificio central, al este y al oeste. La evolución del CVPM se ha interpretado como el resultado de la interacción recurrente entre magmas basálticos y traquíticos, documentada mediante evidencia petrográfica y geoquímica (Hernando *et al.*, 2012, 2016).

Durante el Pleistoceno Tardío se generó una ignimbrita formadora de caldera de amplia distribución (Ignimbrita Portezuelo), la cual constituye un marcador estratigráfico regional. Ese evento define tres estadios evolutivos del CVPM: pre-caldera, sin-caldera y post-caldera (Hernando *et al.*, 2012). El estadio pre-caldera corresponde al período más prolongado de actividad volcánica, con una duración mínima estimada de 600.000 años. Se extiende hasta la erupción de la Ignimbrita Portezuelo, datada entre 148 y 82 ka (Germa *et al.*, 2010; Hernando *et al.*, 2014). Los productos de este estadio están dominados por lavas de composición mayormente traquítica, con menor participación de traquiandesitas y traquiandesitas basálticas (Hernando *et al.*, 2014). Petrográficamente, estas lavas presentan evidencias de desequilibrio, interpretadas como indicativas de procesos magmáticos complejos (Hernando *et al.*, 2012). La actividad pre-caldera de los centros eruptivos aledaños está representada principalmente por basaltos y traquibasaltos (Hernando *et al.*, 2014).

El estadio sin-caldera está representado por la erupción de la Ignimbrita Portezuelo, de composición traquítica, asociada directamente al colapso de la caldera de Payún Matrú (Llambías, 1966; Hernando *et al.*, 2016). De acuerdo con Hernando *et al.* (2016), el desencadenante de la erupción habría sido una recarga de magma máfico en una cámara traquítica.

El volcanismo post-caldera, en tanto, se inició con lavas traquiandesíticas (Germa *et al.*, 2010; Hernando *et al.*, 2014). Estas lavas intermedias marcan un cambio hacia composiciones menos evolucionadas en comparación con la Ignimbrita Portezuelo y productos de estadios previos, y presentan abundantes evidencias texturales indicativas de procesos de mezcla entre magmas basálticos y traquíticos (Hernando *et al.*, 2012). Durante el Holoceno, los productos volcánicos han consistido en lavas y domos de composiciones mayormente traquíticas, así como algunos conos piroclásticos, aunque sin evidencias de mezcla magmática comparables a las observadas en los productos más antiguos (Germa *et al.*, 2010). Para esta etapa, la actividad de los campos basálticos ha consistido principalmente en traquibasaltos y escasos basaltos (Espanon *et al.*, 2014; Hernando *et al.*, 2014; Marchetti *et al.*, 2014).

Hernando *et al.* (2012, 2014, 2016) caracterizaron en detalle la petrografía y la geoquímica de estas unidades y reconstruyeron los principales procesos magmáticos de la evolución del CVPM. Sin embargo, hasta el momento no se han aplicado metodologías CSD en estas rocas. Para evaluar el desempeño de ACSD2D en un contexto volcánico real, en este trabajo se seleccionaron seis secciones delgadas representativas, correspondientes a traquitas pre-caldera, traquiandesitas post-caldera y basaltos pre- y post-caldera provenientes de los centros volcánicos aledaños (Hernando, 2012). Las imágenes se adquirieron y procesaron bajo las mismas condiciones que las de los subconjuntos de entrenamiento, prueba y validación. Las

curvas CSD se construyeron mediante *CSDCorrections* empleando la segmentación automática del modelo siguiendo los criterios de Higgins (2000, 2002, 2006). Estas curvas, así como los diagramas RA- $\sqrt{A}$, fueron comparados con datos obtenidos manualmente.

3.4.1 Descripción de las muestras

Las muestras seleccionadas son porfíricas y están dominadas por fenocristales de plagioclasa acompañados por piroxeno, olivino y anfíbol subordinados. Esas proporciones son estimaciones relativas en sección delgada y no porcentajes modales volumétricos. El modelo se entrenó sobre fenocristales de plagioclasa y no discrimina entre plagioclasa, feldespato alcalino y cuarzo, de modo que la clase segmentada puede incluir cristales de esas otras fases.

Las traquitas pre-caldera están representadas por las muestras Py-10 y Pm-28 (Fig. 7A, B). Ambas son lavas porfíricas con masas fundamentales traquíticas a intergranulares. En Py-10 la plagioclasa es el mineral más abundante, seguida por piroxeno, anfíbol, minerales opacos y apatita. Los cristales de plagioclasa presentan una textura seriada que varía desde microlitos hasta individuos de 6,4 mm de largo. Pm-28 contiene, además, biotita y olivino, con una masa fundamental intergranular bandeada.

Las traquiandesitas post-caldera corresponden a las muestras Pm-34 y Sta-6b (Fig. 7C, D). Pm-34 tiene textura porfírica, con fenocristales de plagioclasa, olivino, piroxeno y minerales opacos en una masa fundamental intergranular. Sta-6b también es porfírica, con fenocristales de plagioclasa, olivino, anfíbol y minerales opacos en una masa fundamental pilotóxica a traquítica.

Los basaltos de los centros aledaños corresponden a las muestras Py-5 y Py-13 (Fig. 7E, F) y tienen bajo contenido de fenocristales (~5 %). Los fenocristales son de plagioclasa, olivino y

piroxeno. La masa fundamental es intergranular, con ocasionales parches vítreos dispersos. Py-5 pertenece a una unidad de basalto pre-caldera y Py-13 a una unidad de basalto post-caldera.




FIG. 7. Fotomicrografías a nicols cruzados representativas de las distintas litologías del CVPM. **A, B.** Traquitas pre-caldera (Py-10 y Pm-28). **C, D.** Traquiandesitas post-caldera (Pm-34 y Sta-6b). **E, F.** Basaltos de los centros eruptivos aledaños (Py-5 y Py-13).

La Tabla 5 resume la proporción relativa de fenocristales y masa fundamental, junto con los parámetros morfométricos de los cristales de plagioclasa. La moda relativa de fenocristales se estimó por conteo y segmentación en secciones delgadas. En las traquitas pre-caldera se registran los cristales de plagioclasa de mayor tamaño, los que alcanzan longitudes máximas de 6,4 mm y promedios superiores a 1 mm. Las traquiandesitas post-caldera presentan dimensiones intermedias, con longitudes máximas cercanas a 5 mm y promedios inferiores a 1 mm. En los basaltos, en tanto, predominan cristales mucho más pequeños, con longitudes máximas menores que 2 mm y promedios cercanos a 0,5 mm (Fig. 7).

Tabla 5. Composición modal de las muestras del CVPM y parámetros morfométricos de los cristales de plagioclasa.

ID	Masa fundamental (%)	Fenocristales (%)	Pl(%)	Px(%)	Ol(%)	Vesicularidad(%)	Pl - Largo máximo (mm)	Pl - Largo medio (mm)	Pl - Ancho máximo (mm)	Pl - Ancho medio (mm)
Traquitas pre-caldera										
Py-10	63,27	36,73	92,80	6,20	0,00	?	6,40	1,13	4,62	0,64
Pm-28	70,54	29,46	90,80	3,00	6,10	?	2,07	0,47	1,96	0,28
Traquiandesitas post-caldera										
Sta-6b	67,80	32,20	87,70	6,40	5,80	5,20	4,42	0,87	1,80	0,37
Pm-34	65,15	34,85	84,10	9,53	6,37	4,23	4,94	0,60	2,31	0,29
Basaltos de los centros eruptivos aledaños										
Py-5	95,00	5,00	61,00	24,00	15,00	?	1,67	0,51	1,34	0,31
Py-13	95,70	4,30	77,10	0,00	22,90	?	1,56	0,47	0,61	0,20

Pl: plagioclasa; Px: piroxeno; Ol: olivino; ?: cantidad indeterminada.

3.4.2 Comparación entre adquisición manual y automática

La segmentación se realizó de manera manual y mediante ACSD2D, de forma independiente en cada caso. La segmentación con ACSD2D identifica correctamente la mayoría de los fenocristales detectados de manera manual (Fig. 8; Fig. S1, material suplementario). En algunas muestras, sin embargo, la segmentación automática sobresegmenta un mismo cristal en varias etiquetas (Fig. 8B, D, F), principalmente en la clase de mayor tamaño ($L > 1$ mm). En otros casos

subsegmenta los cristales incluidos en glomérulos complejos (Fig. 8C), lo que subestima el número real de cristales. La clase $0,75 < L \leq 1$ mm, una de las menos representadas en las muestras estudiadas, tiende a subestimarse. Sus cristales se redistribuyen hacia clases menores, especialmente hacia $0,5 < L \leq 0,75$ mm. Asimismo, ACSD2D mostró dificultades en la segmentación de los cristales más pequeños ($L \leq 0,5$ mm) en masas fundamentales con texturas traquíticas o pilotaxíticas (Fig. S1D, material suplementario).




FIG. 8. Clasificación de los cristales de plagioclasa en tres muestras del CVPM, mediante etiquetado manual y segmentación automática. **A, C, E.** Etiquetado manual a partir de las fotomicrografías de las muestras Pm-28 (traquita pre-caldera), Sta-6b (traquiandesita post-caldera) y Py-13 (basalto post-caldera), respectivamente. **B, D, F.** Segmentación automática con ACSD2D de las mismas muestras. La escala es la misma que en la figura 7. En todos los paneles los colores indican las clases de tamaño: $L \leq 0,5$ mm (amarillo), $0,5 < L \leq 0,75$ mm (verde), $0,75 < L \leq 1$ mm (celeste) y $L > 1$ mm (violeta). Las muestras restantes se presentan en la figura S1 del material suplementario.

En cuanto a los diagramas RA- $\sqrt{A}$ (Fig. 9; Fig. S2, material suplementario) obtenidos a partir de las adquisiciones manuales y automáticas, las traquitas pre-caldera (Fig. 9A, B; Fig. S2A, B, material suplementario) muestran patrones comparables entre ambos métodos. En los datos manuales, los valores de RA oscilan entre ~ 1 y ~ 7 , mientras que $\sqrt{A}$ varía de 0,25 a un máximo de entre 2,5 y 5,5 mm según la muestra. La mayor densidad de observaciones corresponde a la clase $L \leq 0,5$ mm, con una dispersión amplia de RA (entre ~ 1 y ~ 7), lo que indica la presencia de cristales con morfologías que varían desde equidimensionales hasta tabulares. La clase $0,5 < L \leq 0,75$ mm presenta una distribución similar, con menor dispersión de RA. En la muestra Pm-28 no se registraron cristales de esta clase en el etiquetado manual. Las clases de mayor tamaño están representadas por pocos cristales, concentrados en valores de RA bajos (de ~ 2 a ~ 4). Los datos automáticos reproducen esa estructura, aunque acumulan más observaciones en los valores bajos de $\sqrt{A}$ para las dos clases menores ($L \leq 0,75$ mm). En esas clases la dispersión de RA se mantiene entre ~ 1 y ~ 6 , mientras que los cristales de las dos clases mayores ($L > 0,75$ mm) aparecen subrepresentados respecto del etiquetado manual.

Las traquiandesitas post-caldera (Fig. 9C, D; Fig. S2C, D, material suplementario) presentan valores de RA entre 1 y ~ 7 y valores de $\sqrt{A}$ que van desde 0,25 a 2 mm. La mayoría de las observaciones se concentran en la clase $L \leq 0,5$ mm, con $\sqrt{A}$ menor que 0,5 mm y RA en todo el rango medido, al igual que en las traquitas pre-caldera. La clase $0,5 < L \leq 0,75$ mm ocupa un campo parcialmente superpuesto al anterior, con $\sqrt{A}$ de hasta 0,5 mm y RA máximos de 6 a 7,5 según la muestra. Las dos clases mayores ($L > 0,75$ mm) son menos abundantes y se agrupan en campos más restringidos de RA ($\sim 1-4$), con $\sqrt{A}$ más dispersos (0,5-2 mm). En particular, la muestra Sta-6b presenta dos poblaciones de cristales en la clase $L > 1$ mm, una elongada y otra de baja relación de aspecto. Sta-6b es también la muestra con mayor diferencia entre

procedimientos. La segmentación automática desplaza las observaciones hacia tamaños menores y devuelve un conteo total más bajo que el etiquetado manual.

Con respecto a los basaltos tanto pre- como post-caldera (Fig. 9E, F; Fig. S2E, F, material suplementario), los datos manuales muestran una fuerte concentración de cristales en la clase $L \leq 0,5$ mm, con $\sqrt{A}$ menor que 0,4-0,5 mm y RA muy variables, de 1 a 10. La dispersión de RA disminuye a medida que aumenta $\sqrt{A}$. En estas muestras, la segmentación automática reproduce la distribución de $\sqrt{A}$ por clases, pero devuelve valores de RA más acotados, en especial en la clase $L \leq 0,5$ mm, donde los máximos se restringen al intervalo 1-5.




FIG. 9. Diagramas de relación de aspecto (RA) en función de la raíz cuadrada del área ($\sqrt{A}$) para las muestras del CVPM. **A, C, E.** Etiquetado manual de las muestras Pm-28 (traquita pre-caldera), Sta-6b (traquiandesita post-caldera) y Py-13 (basalto post-caldera), respectivamente. **B, D, F.** Segmentación automática con ACSD2D de las mismas muestras. En todos los paneles los colores indican las clases de tamaño: $L \leq 0,5$ mm (amarillo), $0,5 < L \leq 0,75$ mm (verde), $0,75 < L \leq 1$ mm (celeste) y $L > 1$ mm (violeta). Las muestras restantes se presentan en la figura S2 del material suplementario.

La comparación entre ambas metodologías se profundizó mediante histogramas de frecuencia para los ejes mayores y menores de los cristales analizados (Fig. 10; Fig. S3, material suplementario). En términos generales, las distribuciones manuales y automáticas reproducen

las mismas tendencias para los ejes mayores, con la mayoría de los cristales en la clase $L \leq 0,5$ mm. Para los ejes menores, en cambio, se observan discrepancias sistemáticas atribuibles a la sobrestimación de bordes y a la subdivisión de cristales en múltiples etiquetas, lo que genera una dispersión adicional en la segmentación automática. Este efecto se origina en el algoritmo de segmentación, que puede interpretar variaciones internas de textura o contraste como límites de cristales independientes.




FIG. 10. Histogramas de frecuencia de la longitud de los ejes mayor y menor de los cristales de plagioclasa en las muestras del CVPM, según el etiquetado manual (naranja) y la segmentación automática (verde). Los paneles A, C y E corresponden al eje mayor, y los paneles B, D y F, al eje menor. A, B. Traquita pre-caldera (Pm-28). C, D. Traquiandesita post-caldera (Sta-6b). E, F. Basalto post-caldera (Py-13). Las muestras restantes se presentan en la figura S3 del material suplementario.

3.4.3 Curvas CSD

Las curvas CSD, corregidas estereológicamente con *CSDCorrections*, permiten comparar las distribuciones del etiquetado manual y de la segmentación automática (Fig. 11). Las traquitas y las traquiandesitas concuerdan bien entre los dos procedimientos para $L \leq 1$ mm. En los tamaños mayores las curvas divergen, especialmente en la posición de los cambios de pendiente o *kinks*, lo que se traduce en desplazamientos entre métodos y en un mayor rango de dispersión en las curvas obtenidas mediante ACSD2D. En las traquitas pre-caldera, el etiquetado manual muestra un aumento de la densidad de población para L menor que 0,25 mm. La traquiandesita Pm-34 mantiene una pendiente general comparable entre métodos, aunque con una mayor concavidad en la curva obtenida mediante adquisición automática. Finalmente, los basaltos exhiben la mejor concordancia entre curvas manuales y automáticas.




FIG. 11. Curvas CSD de las muestras del CVPM, corregidas estereológicamente con *CSDCorrections*. **A.** Curvas obtenidas a partir del etiquetado manual. **B.** Curvas obtenidas a partir de la segmentación automática con ACSD2D. En ambos paneles cada curva corresponde a una muestra, con los mismos símbolos y colores; la leyenda se muestra en el panel B. Los recuadros interiores reproducen cada curva por separado.

4. DISCUSIÓN

4.1 Desempeño del modelo y métricas

Los resultados muestran que ACSD2D identifica los cristales de plagioclasa en secciones delgadas con un desempeño consistente respecto del etiquetado manual. Las curvas CSD y los diagramas $RA-\sqrt{A}$ generados automáticamente reproducen la tendencia semilogarítmica y la distribución general de tamaños observadas en los datos manuales. Ese desempeño es estable en la clase de menor tamaño ($L \leq 0,5$ mm), con *F1-Score* de 0,80 a 0,96 e IoU de 0,67 a 0,93, y aún mejor en la clase de mayor tamaño ($L > 1$ mm), donde el *F1-Score* alcanza al menos 0,98 y el IoU al menos 0,96 en los tres subconjuntos. Las clases intermedias ($0,5 < L \leq 0,75$ mm y $0,75 < L \leq 1$ mm) presentan mayor dispersión, con *F1-Score* entre 0,62 y 0,90 e IoU entre 0,45 y 0,82. Estas diferencias no se explican únicamente por la frecuencia relativa de las clases. Los cristales de mayor tamaño son menos numerosos, pero ocupan más superficie y tienen bordes mejor definidos, lo que favorece una segmentación más consistente. Por el contrario, los tamaños intermedios combinan mayor complejidad geométrica y menor contraste con la masa fundamental, de modo que sus límites resultan más ambiguos. Este comportamiento refleja la interacción entre desbalance de clases y dificultad geométrica, y explica la mayor dispersión observada en los tamaños intermedios. Estas limitaciones podrían atenuarse mediante estrategias orientadas a mejorar el desempeño en dichas clases, por ejemplo, a través del uso de funciones de pérdida ponderadas (Hossain y Betts, 2021), técnicas de aumento de datos focalizadas (Wu *et al.*, 2022), o regularización adicional (Guan *et al.*, 2022). En las curvas sin corrección estereológica, las discrepancias entre los dos procedimientos se concentran en los cristales fragmentados y en los cristales en contacto. El modelo funciona mejor en muestras con cristales bien separados y pierde algo de precisión en las texturas más densas.

4.2 Otras herramientas útiles para caracterizar fenocristales de plagioclasa

Diversos métodos computacionales han sido desarrollados para la identificación y cuantificación de fenocristales de plagioclasa a partir de imágenes petrográficas. Comparar estos enfoques permite contextualizar el alcance y las limitaciones del modelo implementado en este estudio:

- a) *CEmin* (Zeng *et al.*, 2018) es un conjunto de rutinas en MATLAB para segmentar fenocristales a partir de imágenes en escala de grises mediante umbralado de brillo y operaciones morfológicas como dilatación y antdilatación. Este enfoque está optimizado para imágenes de electrones retrodispersados (BSE), donde el contraste de brillo se correlaciona directamente con la composición química. En este tipo de metodología, la segmentación depende de parámetros definidos por el usuario y de las operaciones morfológicas. Si bien estos procedimientos permiten aislar minerales con éxito, pueden modificar la geometría original de los cristales. La dilatación tiende a fusionar cristales adyacentes o glomérulos, lo que requiere la intervención del usuario, mientras que la antdilatación puede reducir el tamaño de los cristales. Aunque las correcciones posteriores intentan compensar estos efectos, la reconstrucción geométrica no siempre es completa y puede introducir incertidumbre.
- b) *QEMSCAN* (Neave *et al.*, 2014, 2017; Bell *et al.*, 2020) combina información BSE y espectros EDS adquiridos mediante microscopía electrónica de barrido (SEM) para generar mapas mineralógicos automatizados. En este caso, la clasificación depende de la definición del *Species Identification Protocol* (SIP), una base de datos mineralógica que debe ser ajustada por el usuario. Si bien es una herramienta efectiva, su implementación implica costos elevados asociados al uso de SEM-EDS y mantiene un componente dependiente de la parametrización experta.

c) En los últimos años, la aplicación de técnicas de aprendizaje profundo en petrología ha ampliado las capacidades de análisis morfométrico automatizado (Petrelli, 2024; Toth y MacLennan, 2024; Aydın *et al.*, 2025). Dentro de esos avances, Toth y MacLennan (2024) presentaron un enfoque basado en redes neuronales aplicadas a imágenes polarizadas para la segmentación automática de cristales en secciones delgadas. ACSD2D emplea una metodología similar, utilizando imágenes ópticas para cuantificar características morfométricas. Si bien los detalles de implementación (arquitectura de la red, estrategias de entrenamiento y casos de validación) pueden diferir entre estudios, estos enfoques convergen en mostrar que las técnicas de aprendizaje profundo pueden reproducir tendencias cuantitativas de distribución de tamaños, relación de aspecto y formas de cristales. A diferencia de los métodos basados en umbralado o parametrización manual, una vez entrenado, el modelo puede aplicarse sin intervención directa del usuario. Asimismo, el uso de imágenes ópticas representa una alternativa más accesible (y menos costosa) que las basadas en SEM-EDS. En este sentido, los enfoques basados en aprendizaje profundo amplían las posibilidades de automatización del análisis petrográfico, permitiendo obtener mediciones morfométricas reproducibles a partir de imágenes ampliamente disponibles en estudios petrológicos.

4.3 Implicancias petrogenéticas: el caso del CVPM

Las curvas CSD y los diagramas $RA-\sqrt{A}$ obtenidos para las muestras del CVPM permiten discutir procesos magmáticos previamente reconocidos en el sistema, integrando los resultados morfométricos con la información petrológica disponible (Hernando, 2012; Hernando *et al.*, 2014, 2016). En las traquitas pre-caldera, las CSD manuales (Fig. 11A) presentan pendientes complejas, con cambios de concavidad marcados y diferencias significativas entre muestras. Las clases de mayor tamaño ($L > 1$ mm) se encuentran escasamente pobladas y definen

segmentos aproximadamente rectilíneos con pendientes variables, mientras que la clase $L \leq 0,5$ mm muestra una representación relativa mayor. Los diagramas RA- $\sqrt{A}$ manuales y automáticos (Fig. 9A, B; Fig. S2A, B, material suplementario) exhiben una dispersión amplia. En los tamaños pequeños e intermedios coexisten cristales tabulares de alta relación de aspecto junto con cristales con relaciones de aspecto significativamente menores, sugiriendo condiciones de crecimiento variables entre los cristales. Este patrón es consistente con la coexistencia de plagioclasas anhedrales con texturas de disequilibrio (*sieve* y *dusty*) y cristales limpios y euhedrales reportados para estas unidades (Hernando *et al.*, 2012).

Las traquiandesitas post-caldera presentan CSD igualmente complejas, caracterizadas por concavidades positivas en la adquisición manual (Fig. 11A). Las transiciones entre segmentos dominados por cristales pequeños, intermedios y grandes no se manifiestan como quiebres abruptos, sino como desplazamientos progresivos de la pendiente interpretados como *kinks*. Estos *kinks* representan zonas de transición entre dominios de tamaño controlados por distintas relaciones relativas entre nucleación y crecimiento, coherentes con condiciones de cristalización no estacionarias. En los diagramas RA- $\sqrt{A}$ manuales y automáticos (Fig. 9C, D; Fig. S2C, D, material suplementario), la persistencia de una dispersión amplia de relaciones de aspecto, incluso hacia tamaños mayores, indica que los cristales no convergen hacia una única morfología dominante, sino que preservan registros de variaciones en las condiciones de crecimiento. Esta interpretación concuerda con la documentación petrológica, dentro de las mismas muestras, de plagioclasas euhedrales con texturas *dusty* localizadas preferentemente en núcleos con sobrecrecimientos limpios, así como cristales sin evidencias de disequilibrio y otros con texturas tipo *sieve* de distinta intensidad (Hernando *et al.*, 2012).

En contraste, los basaltos muestran CSD cercanas a una relación lineal en escala semilogarítmica en ambas adquisiciones (Fig. 11A, B). De forma consistente, los diagramas RA- $\sqrt{A}$ manuales y automáticos (Fig. 9E, F; Fig. S2E, F, material suplementario) presentan una dispersión más acotada, lo que sugiere una evolución morfométrica relativamente homogénea y condiciones de cristalización más estables. Este comportamiento concuerda con la predominancia de plagioclasas limpias, con escasa presencia de núcleos con texturas tipo *sieve*, reportada para estas litologías (Hernando *et al.*, 2012). Esta relativa simplicidad textural también se condice con estudios previos que indican que estos basaltos no tuvieron interacción con los magmas de la cámara principal. No obstante, ello no implica que se trate de magmas primarios, ya que estos basaltos registran procesos de diferenciación en reservorios corticales profundos (Hernando *et al.*, 2012, 2019).

4.4 Limitaciones del modelo y discrepancias observadas

Tanto en las muestras de validación interna como externa del modelo, los resultados muestran que la segmentación automática reproduce adecuadamente las tendencias globales observadas en las curvas CSD y en los diagramas RA- $\sqrt{A}$, manteniendo la estructura general de las distribuciones incluso en imágenes texturalmente complejas. Con respecto a la validación externa, las discrepancias se concentran en los cristales de la clase $L \leq 0,5$ mm o en glomérulos donde los límites individuales resultan difíciles de discriminar incluso bajo análisis manual, lo cual aumenta la densidad de cristales con relaciones de aspecto bajas y $\sqrt{A}$ subestimadas. El análisis cruzado de datos automáticos y manuales, combinado con la categorización textural, permite no solo validar parcialmente la segmentación automática, sino también interpretar procesos magmáticos complejos a partir de la distribución y forma de los cristales. La integración de ambas aproximaciones resulta útil para estudios petrográficos detallados y muestra el alcance de este tipo de metodologías en sistemas volcánicos de evolución compleja.

ACSD2D fue diseñado para delimitar contornos externos y no para reconocer texturas internas, zonaciones o evidencias de desequilibrio mineral. Esta limitación no afecta la coherencia morfométrica global, pero sí delimita el alcance interpretativo cuando se busca integrar forma externa y microtextura en un mismo análisis. El desarrollo futuro de modelos multiclase o de segmentación jerárquica podría permitir una integración más completa entre morfometría y texturas internas. Asimismo, podría incorporarse en esquemas de trabajo multitécnicos donde se combinan curvas CSD y composición química mineral. En estudios como los de Higgins y Roberge (2007), Salisbury *et al.* (2008) o Mangler *et al.* (2022), por ejemplo, la identificación de poblaciones cristalinas diferenciadas permitió reconstruir eventos magmáticos de mezcla, recarga o residencia prolongada. La posibilidad de generar automáticamente grandes volúmenes de datos morfométricos abre nuevas perspectivas para el estudio de la dinámica magmática a escala fina.

El modelo ACSD2D no busca reemplazar el análisis manual sino complementarlo, especialmente en estudios que requieran la caracterización de grandes volúmenes de muestras. ACSD2D se consolida como una herramienta metodológica relevante para la caracterización de fenocristales de plagioclasa en rocas volcánicas, y evidencia el potencial de las técnicas de inteligencia artificial en el campo de las geociencias. En este sentido, la reducción significativa del tiempo de análisis, también destacada por Toth y MacLennan (2024), permite aumentar la resolución de los estudios petrogenéticos y mejorar la capacidad de detección de eventos magmáticos discretos.

5. CONCLUSIONES

La herramienta ACSD2D integra un modelo de segmentación semántica multiclase, basado en técnicas de aprendizaje profundo, para la identificación automática de fenocristales de

plagioclasa en imágenes de secciones delgadas de rocas volcánicas y la generación de curvas CSD y diagramas RA- $\sqrt{A}$. ACSD2D reproduce de manera consistente, dentro de márgenes de error aceptables para tareas de reconocimiento, las distribuciones de tamaños y las tendencias morfométricas generadas manualmente en imágenes que no se utilizaron durante el entrenamiento del modelo. La aplicación exitosa de ACSD2D en un contexto real remarca la utilidad de este tipo de herramientas, en donde las curvas CSD y los diagramas RA- $\sqrt{A}$ generados automáticamente resultan coherentes con interpretaciones petrológicas previas.

En conjunto, los resultados validan el uso de modelos entrenados con inteligencia artificial como herramientas eficientes para detectar tamaños de cristales y generar grandes volúmenes de datos morfométricos con rapidez y consistencia. Esto resulta de especial interés en estudios preliminares de interpretación textural, donde estos modelos pueden complementar los estudios tradicionales y contribuir a la interpretación de procesos como la nucleación, el crecimiento, la recarga magmática o la mezcla, en especial cuando se integran con datos geoquímicos o isotópicos.

ACSD2D no reemplaza el análisis petrográfico tradicional ni reconoce texturas internas, pero tiene la capacidad de reducir significativamente el tiempo de procesamiento al trabajar con grandes volúmenes de datos de manera consistente, lo que lo convierte en una herramienta complementaria especialmente útil para investigaciones preliminares o exploratorias. A futuro, el desarrollo de modelos que incorporen la segmentación de texturas internas o la clasificación jerárquica de cristales podría ampliar el alcance de este enfoque. La inclusión de la corrección estereológica dentro del propio flujo de trabajo permitiría, además, una caracterización automatizada más precisa de los sistemas ígneos.

AGRADECIMIENTOS

Agradecemos sinceramente a F. Escribano, E. Morgado y J. C. de Obeso, y a dos revisores anónimos, que colaboraron durante las distintas etapas de revisión y contribuyeron a la mejora sustancial de nuestro trabajo. Asimismo, expresamos nuestro reconocimiento al Centro de Investigaciones Geológicas (CIG) y al Instituto de Recursos Minerales (INREMI) por brindar el espacio y las facilidades para el desarrollo de esta investigación. Un agradecimiento especial a la Cátedra de Petrología Ígnea (FCNyM, UNLP) por facilitar el acceso a su colección de secciones delgadas, y a la Dra. Irene Hernando por autorizar el uso del material petrográfico perteneciente a su tesis doctoral. Este trabajo fue financiado por la Universidad Nacional de La Plata (UNLP) y el Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Finalmente, expresamos nuestro reconocimiento a las comunidades de *Numpy*, *Scikit-Learn*, *TensorFlow*, *OpenCV*, *Matplotlib*, *Seaborn* y *Github*, cuyas herramientas de cálculo numérico, aprendizaje automático y visualizaciones de datos de código abierto han sido fundamentales para el desarrollo e implementación de este trabajo.

REFERENCIAS

- Armienti, P. 2008. Decryption of Igneous Rock Textures: Crystal Size Distribution tools. *Reviews in Mineralogy and Geochemistry*, 69(1), 623-649.
<https://doi.org/10.2138/rmg.2008.69.16>
- Arthur, D.; Vassilvitskii, S. 2006. How slow is the k-means method? *In Proceedings of the Twenty-Second Annual Symposium on Computational Geometry*: 144-153.
<https://doi.org/10.1145/1137856.1137880>.
- Aydın, İ.; Şener, T.; Kılıç, A.; Derviş, H. 2025. Classification of Thin-Section Rock Images Using a Combined CNN and SVM Approach. *Minerals* 15 (9): 976.
<https://doi.org/10.3390/min15090976>

- Bejnordi, B.E.; Veta, M.; van Diest, P.J.; van Ginneken, B.; Karssemeijer, N.; Litjens, G.; et al. 2017. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA*, 318(22): 2199-2210.
- Bell, S.K.; Joy, K.H.; Pernet-Fisher, J.F.; Hartley, M.E. 2020. QEMSCAN as a Method of Semi-Automated Crystal Size Distribution Analysis: Insights from Apollo 15 Mare Basalts. *Journal of Petrology* 61 (4): 1-20. <https://doi.org/10.1093/petrology/egaa047>
- Burkov, A. 2019. The hundred-page machine learning book. Andriy Burkov: 300 p.
- Cashman, K.V. 1993. Relationship between plagioclase crystallization and cooling rate in basaltic melts. *Contributions to Mineralogy and Petrology*, 113(1): 126-142.
- Cashman, K.V. 2020. Crystal size distribution analysis of volcanic samples: Advances and challenges. *Frontiers in Earth Science*, 8: 291.
- Cashman, K.V.; Marsh, B.D. 1988. Crystal size distribution (CSD) in rocks and the kinetics and dynamics of crystallization II: Makaopuhi lava lake. *Contributions to Mineralogy and Petrology*, 99(3): 292-305. <https://doi.org/10.1007/BF00375363>
- Chen, C.; Seff, A.; Kornhauser, A.; Xiao, J. 2015. DeepDriving: Learning affordance for direct perception in autonomous driving. *In Proceedings of the IEEE International Conference on Computer Vision*: 2722-2730.
- Chollet, F. 2021. Deep Learning with Python. Simon y Schuster: 384 p.
- Csurka, G.; Larlus, D.; Perronnin, F.; Meylan, F. 2013. What is a good evaluation measure for semantic segmentation?. *In BMVC*, 27: 10-5244.

Dice, L.R. 1945. Measures of the amount of ecologic association between species. *Ecology*, 26(3): 297-302.

Espanon, V.R.; Honda, M.; Chivas, A.R. 2014. Cosmogenic ^3He and ^{21}Ne surface exposure dating of young basalts from Southern Mendoza, Argentina. *Quaternary Geochronology* 19: 76-86.

Everingham, M.; Van Gool, L.; Williams, C.K.; Winn, J.; Zisserman, A. 2010. The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision* 88 (2): 303-338. <https://doi.org/10.1007/s11263-009-0275-4>.

Fornaciai, A.; Perinelli, C.; Armienti, P.; Favalli, M. 2015. Crystal size distributions of plagioclase in lavas from the July–August 2001 Mount Etna eruption. *Bulletin of Volcanology*, 77(8): 70.

Germa, A.; Quidelleur, X.; Gillot, P.Y.; Tchilinguirian, P. 2010. Volcanic evolution of the back-arc Pleistocene Payun Matru volcanic field (Argentina). *Journal of South American Earth Sciences* 29 (3): 717-730.

Goodfellow, I.; Bengio, Y.; Courville, A. 2016. *Deep Learning*. MIT Press, Cambridge, 800 p.

Guan, D.; Huang, J.; Xiao, A.; Lu, S. 2022. Unbiased Subclass Regularization for Semi-Supervised Semantic Segmentation. *In Proceedings of the IEEE/CVF conference on Computer Vision and Pattern Recognition*: 9968-9978. <https://arxiv.org/abs/2203.10026>

Haque, I.R.I.; Neubert, J. 2020. Deep learning approaches to biomedical image segmentation. *Informatics in Medicine Unlocked*, 18: 100297.

Hastie, T.; Tibshirani, R.; Friedman, J. 2009. *The Elements of Statistical Learning*. Springer: 745 p.

He, H. 2023. Segment Anything Annotator. Repositorio en línea. Disponible en: <https://github.com/haochenheheda/segment-anything-annotator> [último acceso: 11 de julio de 2025].

He, X.; Zemel, R.; Carreira, J.; Urtasun, R. 2015. Object-level reasoning in video semantic segmentation. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2015: 3009-3017. <https://doi.org/10.1109/ICCV.2015.345>

Hernando, I.R. 2012. Evolución volcánica y petrológica del Volcán Payún Matrú, retroarco andino del sudeste de Mendoza. Memoria de Título, Universidad Nacional de La Plata, Facultad de Ciencias Naturales y Museo (FCNyM): 358 p.

Hernando, I.R.; Llambías, E.J.; González, P.D.; Sato, K. 2012. Volcanic stratigraphy and evidence of magma mixing in the Quaternary Payún Matrú volcano, Andean backarc in western Argentina. *Andean Geology*, 39(1): 158-179.

Hernando, I.R.; Aragón, E.; Frei, R.; González, P.D.; Spakman, W. 2014. Constraints on the origin and evolution of magmas in the Payún Matrú Volcanic Field, Quaternary andean back-arc of Western Argentina. *Journal of Petrology* 55 (1): 209-239.

Hernando, I.R.; Petrinovic, I.A.; Llambías, E.J.; D'Elia, L.; González, P.D.; Aragón, E. 2016. The role of magma mixing and mafic recharge in the evolution of a back-arc quaternary caldera: The case of Payún Matrú, Western Argentina. *Journal of Volcanology and Geothermal Research*, 311: 150-169. <https://doi.org/10.1016/j.jvolgeores.2016.01.008>.

Hernando, I.R.; Petrinovic, I.A.; Gutiérrez, D.A.; Bucher, J.; Fuentes, T.G.; Aragón, E. 2019. The caldera-forming eruption of the quaternary Payún Matrú volcano, Andean back-arc of the southern volcanic zone. *Journal of Volcanology and Geothermal Research*, 384: 15-30.

Higgins, M.D. 1996. Crystal size distributions and other quantitative textural measurements in lavas and tuff from Mt Taranaki (Egmont volcano), New Zealand. *Bulletin of Volcanology*, 58: 194-204.

Higgins, M.D. 2000. Measurement of crystal size distributions. *American Mineralogist*, 85(9): 1105-1116. <https://doi.org/10.2138/am-2000-8-901>.

Higgins, M.D. 2002. Closure in crystal size distributions (CSD), verification of CSD calculations, and the significance of CSD fans. *American Mineralogist* 87 (1): 171-175. <https://doi.org/10.2138/am-2002-0118>.

Higgins, M.D. 2006. Verification of ideal semi-logarithmic, lognormal or fractal crystal size distributions from 2D datasets. *Journal of Volcanology and Geothermal Research*, 154(1-2): 8-16. <https://doi.org/10.1016/j.jvolgeores.2005.09.015>.

Higgins, M.D.; Roberge, J. 2007. Three magmatic components in the 1973 eruption of Eldfell volcano, Iceland: Evidence from plagioclase crystal size distribution (CSD) and geochemistry. *Journal of Volcanology and Geothermal Research*, 161(3): 247-260.

Holness, M.B. 2014. The effect of crystallization time on plagioclase grain shape in dolerites. *Contributions to Mineralogy and Petrology*, 168(5): 1076. <https://doi.org/10.1007/s00410-014-1076-5>.

Hossain, M.S.; Betts, J. 2021. Dual Focal Loss to address class imbalance in semantic segmentation. *Pattern Recognition Letters*, 148 (1-8). <https://doi.org/10.1016/j.patrec.2021.10.008>

Jaccard, P. 1912. The distribution of the flora in the alpine zone. 1. *New Phytologist*, 11(2): 37-50.

Jordan, M.I.; Mitchell, T.M. 2015. Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245): 255-260.

Kingma, D.P.; Ba, J. 2015. Adam: A method for stochastic optimization. *In* International Conference on Learning Representations (ICLR 2015) *arXiv:1412.6980*. 3: 1-15. San Diego. <https://doi.org/10.48550/arXiv.1412.6980>

Kirillov, A.; Mintun, E.; Ravi, N.; Mao, H.; Rolland, C.; Gustafson, L. 2023. Segment anything. *In* Proceedings of the IEEE/CVF International Conference on Computer Vision: 4015-4026. <https://doi.org/10.48550/arXiv.2304.02643>.

Latif, G.; Bouchard, K.; Maitre, J.; Back, A.; Bédard, L.P. 2022. Deep-Learning-Based Automatic Mineral Grain Segmentation and Recognition. *Minerals* 12 (4): 455. <https://doi.org/10.3390/min12040455>

Llambías, E.J. 1966. Geología y petrología del volcán Payún Matrú. *Acta Geológica Lilloana* 8: 265-315.

Lloyd, S. 1982. Least Squares Quantization in PCM. *IEEE Transactions on Information Theory*, 28: 129-137.

Long, J.; Shelhamer, E.; Darrell, T. 2015. Fully Convolutional Networks for Semantic Segmentation. *In* Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR): 3431-3440. Boston.

Mangler, M.F.; Humphreys, M.C.; Wadsworth, F.B.; Iveson, A.A.; Higgins, M.D. 2022. Variation of plagioclase shape with size in intermediate magmas: a window into incipient plagioclase crystallisation. *Contributions to Mineralogy and Petrology*, 177(6): 64. <https://doi.org/10.1007/s00410-022-01922-9>

- Marchetti, D.W.; Hynek, S.A.; Cerling, T.E. 2014. Cosmogenic ^3He exposure ages of basalt flows in the northwestern Payún Matrú volcanic field, Mendoza province, Argentina. *Quaternary Geochronology* 19: 67-75.
- Marsh, B.D. 1988. Crystal size distribution (CSD) in rocks and the kinetics and dynamics of crystallization: I. Theory. *Contributions to Mineralogy and Petrology*, 99(3): 277-291.
- Martí-Isasi, A. 2023. *Automatic segmentation of minerals in thin sections using deep learning*. GitHub repository, available at: <https://github.com/amartiis/thinsection-segmentation>
- Milletari, F.; Navab, N.; Ahmadi, S. 2016. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. *2016 Fourth International Conference on 3D Vision (3DV)*. 565-571. 10.1109/3DV.2016.79
- Minaee, S.; Boykov, Y.; Porikli, F.; Plaza, A.; Kehtarnavaz, N.; Terzopoulos, D. 2021. Image segmentation using deep learning: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7): 3523-3542.
- Murphy, K.P. 2012. *Machine learning: a probabilistic perspective*. MIT Press, Cambridge, 1067 p.
- Neave, D.A.; MacLennan, J.; Hartley, M.E.; Edmonds, M.; Thordarson, T. 2014. Crystal storage and transfer in basaltic systems: the Skuggafjöll eruption, Iceland. *Journal of Petrology*, 55(12): 2311-2346. <https://doi.org/10.1093/petrology/egu058>.
- Neave, D.A.; Buisman, I.; MacLennan, J. 2017. Continuous mush disaggregation during the long-lasting Laki fissure eruption, Iceland. *American Mineralogist*, 102(10): 2007-2021. <https://doi.org/10.2138/am-2017-6015CCBY>.

- Papadeas, I.; Tzelepi, M.; Tefas, A. 2021. Real-time semantic image segmentation with deep learning for autonomous driving: A survey. *Applied Sciences*, 11(19): 8802. <https://doi.org/10.3390/app11198802>
- Petrelli, M. 2024. Machine Learning in Petrology: State-of-the-Art and Future Perspectives. *Journal of Petrology* 65 (5): egae036.
- Polanski, J. 1954. Rasgos geomorfológicos del territorio de la provincia de Mendoza. Ministerio de Economía, Instituto de Investigaciones Económicas y Tecnológicas. Cuaderno de Investigaciones y Estudios, 4: 4-10.
- Powers, D.M. 2011. Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2 (1): 37-63.
- Rahman, M.A.; Wang, Y. 2016. Optimizing intersection-over-union in deep neural networks for image segmentation. *In International Symposium on Visual Computing*: 234-244. Springer, Cham.
- Reinke, A.; Tizabi, M.D.; Sudre, C.H.; Eisenmann, M.; Rädtsch, T.; Baumgartner, M.; Acion, L.; Antonelli, M.; Arbel, T.; Bakas, S.; Jäger, P.; Maier-Hein, L; *et al.* 2021. Common Limitations of Image Processing Metrics: A Picture Story. arXiv:2104.05642. <https://doi.org/10.48550/arXiv.2104.05642>
- Ronneberger, O.; Fischer, P.; Brox, T. 2015. U-net: Convolutional networks for biomedical image segmentation. *In International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*: 234-241. Springer, Cham.
- Salisbury, M.J.; Bohrsen, W.A.; Clynne, M.A.; Ramos, F.C.; Hoskin, P. 2008. Multiple plagioclase crystal populations identified by crystal size distribution and in situ chemical

data: implications for timescales of magma chamber processes associated with the 1915 eruption of Lassen Peak, CA. *Journal of Petrology*, 49(10): 1755-1780. <https://doi.org/10.1093/petrology/egn045>

Save, A. 2020. *Multiclass Semantic Segmentation on CamVid Dataset* [Repositorio de GitHub], GitHub. <https://github.com/advaitsave/Multiclass-Semantic-Segmentation-CamVid>

Smith, J.V.; Brown, W.L. 1988. *Feldspar minerals. Vol. 1: Crystal structure and physical properties*. Springer-Verlag, Berlin, 828 p.

Toth, N.; MacLennan, J.A. 2024. MinDet1: A deep learning-enabled approach for plagioclase textural studies. *Volcanica*, 7(1): 135-151.

Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A.N.; Kaiser, L.; Polosukhin, I. 2017. Attention is all you need. *In Advances in Neural Information Processing Systems*: 5998-6008.

Wu, L.; Zhang, Y.; Zhang, Z. 2022. Data augmentation based on multiple oversampling fusion for class-imbalanced semantic segmentation. *PLOS ONE* 17(10), e0274522. <https://doi.org/10.1371/journal.pone.0274522>

Zeng, L.; Cheng, L.; Costa, F.; Herrin, J. 2018. CEmin: a MATLAB-based software for computational phenocryst extraction and statistical petrology. *Geochemistry, Geophysics, Geosystems*, 19(4), 1378-1392. <https://doi.org/10.1002/2017GC007346>

MATERIAL SUPLEMENTARIO




Fig. S1. Clasificación de los cristales de plagioclasa en tres muestras del CVPM, mediante etiquetado manual y segmentación automática. **A, C, E.** Etiquetado manual a partir de las fotomicrografías de las muestras Py-10 (traquita pre-caldera), Pm-34 (traquiandesita post-caldera) y Py-5 (basalto pre-caldera), respectivamente. **B, D, F.** Segmentación automática con ACSD2D de las mismas muestras. La escala es la misma que en la figura 7. En todos los paneles los colores indican las clases de tamaño: $L \leq 0,5$ mm (amarillo), $0,5 < L \leq 0,75$ mm (verde), $0,75 < L \leq 1$ mm (celeste) y $L > 1$ mm (violeta). Las muestras restantes se presentan en la figura 8 del texto.




Fig. S2. Diagramas de relación de aspecto (RA) en función de la raíz cuadrada del área ($\sqrt{A}$) para las muestras del CVPM. **A, C, E.** Etiquetado manual de las muestras Py-10 (traquita pre-caldera), Pm-34 (traquiandesita post-caldera) y Py-5 (basalto pre-caldera), respectivamente. **B, D, F.** Segmentación automática con ACSD2D de las mismas muestras. En todos los paneles los colores indican las clases de tamaño: $L \leq 0.5$ mm (amarillo), $0.5 < L \leq 0.75$ mm (verde), $0.75 < L \leq 1$ mm (celeste) y $L > 1$ mm (violeta). Las muestras restantes se presentan en la figura 9 del texto.




Fig. S3. Histogramas de frecuencia de la longitud de ejes mayor y menor de los cristales de palgioclasa en las muestras del CVPM, según el etiquetado manual (naranja) y la segmentación automática (verde). Los paneles **A**, **C** y **E** corresponden al eje mayor, y los paneles **B**, **D** y **F**, al eje menor. **A**, **B**. Traquita pre-caldera (Py-10). **C**, **D**. Traquiandesita post-caldera (Pm-34). **E**, **F**. Basalto pre-caldera (Py-5). Muestras restantes disponibles en la figura 10 del texto.