



PERÚ

Ministerio  
del Ambiente



# DETECCIÓN Y CARÁCTERIZACIÓN AUTOMÁTICA DE EXPLOSIONES VOLCÁNICAS Y SU APOORTE A LA GRD: CASO VOLCÁN SABANCAYA

Informe Técnico N°047-2024/IGP CIENCIAS DE LA TIERRA SÓLIDA



Lima - Perú  
Diciembre, 2024

## **Instituto Geofísico del Perú**

Presidente Ejecutivo: Hernando Tavera

Director Científico: Edmundo Norabuena

## **Informe Técnico**

Detección y caracterización automática de explosiones volcánicas y su aporte a la GRD:  
Caso volcán Sabancaya.

## **Autores:**

Riky Gustavo  
Milagros Gómez  
Javier Vilca  
Ivonne Lazarte  
Efrain Mayhua

Este informe ha sido producido por el Instituto Geofísico del Perú  
Calle Badajoz 169 Mayorazgo  
Teléfono: 51-1-3172300

**DETECCIÓN Y CARACTERIZACIÓN AUTOMÁTICA DE  
EXPLOSIONES VOLCÁNICAS Y SU APOORTE A LA GRD:  
CASO VOLCÁN SABANCAYA**

Arequipa – Perú  
Diciembre, 2024

## **RESUMEN**

Se presenta la implementación de un sistema multiparamétrico para la detección en tiempo real y caracterización de explosiones del volcán Sabancaya a partir del uso de imágenes, señales sísmicas y datos meteorológicos de 1343 explosiones registradas entre 2019 y 2021. Asimismo, se aplicaron técnicas de redes neuronales convolucional U-Net, para segmentar y medir parámetros de las plumas volcánicas en imágenes y algoritmos de aprendizaje automático supervisado para clasificar los sismos, especialmente aquellos relacionados con eventos eruptivos. Los resultados demuestran la efectividad del uso de inteligencia artificial en el procesamiento de grandes volúmenes de datos generados durante crisis sísmicas y eruptivas. La red U-Net logró una segmentación precisa de las plumas volcánicas en imágenes, con una precisión superior al 98% y capacidad de generalización con datos nuevos. Por otro lado, el clasificador CatBoost obtuvo una precisión promedio del 94.5% en la clasificación e identificación de eventos sísmicos del volcán. Estos enfoques permiten inferir parámetros eruptivos en tiempo real sin intervención humana, a partir del análisis de información visual y sísmica durante las fases tempranas de los eventos explosivos. Es destacable la alta sensibilidad de los modelos para detectar explosiones intensas con altas columnas eruptivas, lo cual es relevante para el desarrollo de sistemas confiables de alerta temprana ante posibles erupciones volcánicas.

## **CONTENIDO**

### **RESUMEN**

#### **1.- INTRODUCCIÓN**

#### **2.- CONTEXTO VULCANOLÓGICO**

##### **2.1.- Historia eruptiva**

##### **2.2.- Actividad explosiva del volcán Sabancaya**

#### **3.- METODOLOGÍA Y DATOS**

##### **3.1.- Análisis de imágenes**

##### **3.2.- Análisis de datos sísmicos**

##### **3.3.- Datos meteorológicos**

#### **4.- RESULTADOS**

##### **4.1.- Segmentación de imágenes**

##### **4.2.- Caracterización de la pluma volcánica**

##### **4.3.- Clasificación automática de señales sísmicas**

##### **4.4.- Caracterización de la pluma volcánica en condiciones adversas**

#### **5.- DISCUSIÓN**

##### **5.1.- Sismos asociados a explosiones de ceniza**

##### **5.2.- Estimación del tamaño de columnas eruptivas**

##### **5.3.- Potencial para alerta temprana cuantitativa**

### **CONCLUSIONES**

### **BIBLIOGRAFÍA**

### **APÉNDICE 1**

### **APÉNDICE 2**

## **1. INTRODUCCIÓN**

Durante las últimas tres décadas, el Perú ha sido testigo de lo fascinante y a la vez devastadora actividad volcánica explosiva en el mundo, con un registro de seis procesos eruptivos. Cuatro de ellos ocurrieron en el volcán Ubinas; mientras que, los otros dos tuvieron lugar en el volcán Sabancaya que durante el periodo 2019-2021 experimentó una serie de explosiones vulcanianas que emitieron gases y cenizas a la atmósfera en forma de plumas eruptivas, alcanzando ocasionalmente alturas superiores a los 4 km. Estas erupciones representan diversos peligros a nivel local y constituyen una amenaza para las personas, el tráfico aéreo, la agricultura y la infraestructura (Jenkins et al., 2015; Wilson et al., 2014; Wilson et al., 2015).

Para prevenir y reducir el riesgo volcánico, es fundamental estudiar y caracterizar los productos emitidos por los volcanes, así como realizar un monitoreo constante de las explosiones volcánicas y su dinámica en superficie. Ello se logra a través de dos parámetros: la altura y la tasa de crecimiento máxima de una columna eruptiva. Estos parámetros tienen especial relevancia al momento de evaluar su impacto en áreas pobladas, a través del modelamiento de la dispersión y caída de cenizas (Folch, 2012; Hasegawa et al., 2015). Sin embargo, medir directamente estos parámetros en tiempo real durante eventos explosivos es un gran desafío y no es factible para la gran mayoría de los volcanes en el mundo (p. ej., Mastin et al., 2009; Scollo et al., 2009; Sciotto et al., 2019). Aunque existen sistemas de teledetección costosos que utilizan radar y LiDAR para recuperar dicha información en tiempo real, solo se utilizan en algunos volcanes (p. ej., Scollo et al., 2012; Marzano et al., 2015).

En este contexto, el uso de estaciones sísmicas y cámaras de video convencionales para el monitoreo volcánico ha demostrado ser una herramienta valiosa para tal fin. Los sismómetros detectan las ondas generadas por las explosiones volcánicas, incluso minutos antes de que la columna eruptiva sea

visible en las cámaras. De esta manera, al analizar en tiempo real las formas de onda sísmicas asociadas, es posible obtener la altura y la tasa de crecimiento de una columna eruptiva, lo que permite una alerta temprana efectiva (Prejean & Brodsky, 2011; Poli & Shapiro, 2022). Sin embargo, se necesitan métodos robustos de procesamiento de señales y sistemas de clasificación de eventos sísmicos en tiempo real.

Durante períodos de intranquilidad volcánica o procesos eruptivos, se generan grandes cantidades de datos que resultan difíciles de analizar y dificultan el seguimiento preciso de la actividad volcánica. En respuesta a esta situación, el uso de técnicas de inteligencia artificial (IA), como el aprendizaje automático (ML) y el aprendizaje profundo (DL), ha surgido como una solución potencial al problema. La inteligencia artificial se refiere al campo de estudio que permite a las máquinas imitar comportamientos inteligentes (Russell & Norvig, 2016). Por otro lado, el aprendizaje automático es una rama específica de la inteligencia artificial que se enfoca en permitir a las computadoras aprender de los datos, sin necesidad de conocer explícitamente su naturaleza (Mitchell, 2022). En cuanto al aprendizaje profundo, es un subcampo del aprendizaje automático que se centra en el desarrollo de algoritmos capaces de aprender y realizar tareas utilizando redes neuronales artificiales, y tiene un gran potencial en el procesamiento de datos no estructurados, como la detección de objetos en imágenes. Sin embargo, en el Perú se han realizado pocos estudios al respecto, la mayoría de los cuales se han centrado en el volcán Ubinas, especialmente en la clasificación automática de sismos de origen volcánico (Malfante et al., 2018b; Lara et al., 2020; Centeno y Rivera, 2020; Peixoto et al., 2021).

En este estudio, se propone un sistema de monitoreo casi en tiempo real de la actividad explosiva del volcán Sabancaya usando técnicas convencionales de ML y DL para analizar señales sísmicas e imágenes y así, detectar y confirmar eventos eruptivos, caracterizar su tamaño y la tasa de crecimiento de una columna eruptiva máxima. Los resultados demuestran el potencial de este enfoque para una alerta temprana frente a peligros volcánicos explosivos.

## **2. CONTEXTO VULCANOLÓGICO**

El Sabancaya ( $15^{\circ} 49.3' S$ ,  $71^{\circ} 52.7' O$ , 5967 m s. n. m.) es uno de los volcanes más activos y jóvenes del sur del Perú, se ubica en el departamento de Arequipa, provincia de Caylloma, a 18 km al sur del valle del Colca y 70 km al noroeste de la ciudad de Arequipa. Asimismo, se encuentra en la Zona Volcánica Central (ZVC) de los Andes, la cual es una zona tectónicamente activa, ubicada en el Arco Volcánico del Sur de Perú. Esta región es el resultado de la subducción de la Placa de Nazca bajo la Placa Sudamericana, lo que ha generado una intensa actividad volcánica a lo largo de los siglos. En este apartado, se menciona la historia eruptiva del volcán Sabancaya, así como un breve resumen sobre las principales características de su actividad eruptiva registrada durante los años 2019 y 2021.

### **2.1. Historia eruptiva**

El volcán Sabancaya, durante su formación, ha experimentado tanto estilos eruptivos efusivos como explosivos. Sin embargo, en tiempos más recientes, su comportamiento ha sido principalmente efusivo, emitiendo amplias coladas de lava en bloques que se distribuyen por varios kilómetros alrededor del cráter. Además, se tiene registro de actividad explosiva ocurrida en el Holoceno, con dos depósitos de tefra bien conservados emplazados entre 4.5 ka y 3 ka, al sureste del volcán (Samaniego et al., 2016). Durante el siglo XVII o XVIII, presentó erupciones explosivas (Travada y Córdova, 1752), que depositaron una capa de ceniza gruesa de 10 a 30 cm de espesor (Juvigné et al., 2008). Durante el siglo XX, específicamente desde 1986 hasta 1998, presentó una erupción explosiva de tipo vulcaniana (VEI 2), la cual comenzó oficialmente el 29 de mayo de 1990 (Gerbe y Thouret, 2004). Esta actividad se caracterizó por la emisión de ceniza y gases en forma de columnas de 5 y 7 km de altura.

El proceso de reactivación de la actividad eruptiva actual del volcán Sabancaya comenzó en 2012, con un aumento de las emisiones de gases y la sismicidad (Jay et al., 2015; Machacca et al., 2023). La actividad magmática se inició el 6 de noviembre de 2016 (MacQueen et al., 2020). Desde entonces, Sabancaya ha mostrado una actividad explosiva intermitente caracterizada por varias explosiones vulcanianas al día. En general, las alturas de las plumas han disminuido progresivamente desde el inicio de la erupción (Coppola et al., 2022), alcanzando alturas de hasta 5.5 km sobre la cima del volcán en julio de 2017 (Manrique et al., 2018) y de 4 km sobre el cráter en 2020 (Machacca et al., 2021).

## **2.2. Actividad explosiva del volcán Sabancaya**

La actividad explosiva del volcán Sabancaya en el año 2019 mostró cambios notables respecto a su energía liberada diariamente y que oscilaban entre 0.01 y 90 megajoules (MJ). En número, se registró un promedio de alrededor de 50 explosiones por día (Coppola et al., 2022). Una aceleración en los niveles de actividad explosiva sugería una intensificación en la actividad efusiva del volcán, puesto en evidencia por un crecimiento de domo de lava entre septiembre y noviembre de 2019 (Fig. 1a). Durante este período, el área basal del domo se triplicó, alcanzando una superficie de  $57 \times 10^3$  metros cuadrados (Machacca et al., 2023). Asimismo, se observó un incremento en la sismicidad volcano-tectónico distal (VTD) en el edificio volcánico justo antes de este pulso efusivo y que se interpretó como una intrusión magmática poco profunda. En conjunto, estos indicios sugieren que la actividad explosiva del volcán Sabancaya en 2019 probablemente estuvo impulsada por procesos de convección magmática en niveles someros, los cuales también contribuyeron al crecimiento del domo de lava (Coppola et al., 2022).

Durante el año 2020, la actividad explosiva del volcán fue menos intensa respecto al año 2019, tanto en términos de energía como de frecuencia. En los primeros meses de 2020, se observó una disminución significativa en la actividad eruptiva, con un máximo de 10 explosiones por día, una energía promedio inferior

a 0.2 MJ y alturas de columna inferiores a 2000 m (Machacca et al., 2021) (Fig. 1a). Durante este período, también se registró una reducción en las anomalías térmicas detectadas por los sensores satelitales (Coppola et al., 2022). Sin embargo, a partir de septiembre de 2020, se observó una nueva extrusión de domo, lo que marcó el comienzo de un nuevo incremento en la actividad explosiva del volcán. Durante los últimos meses de 2020, se registró un aumento tanto en el número de explosiones (26 por día) como en su energía (Machacca et al., 2021). Al igual que en 2019, estos pulsos explosivos parecen estar directamente relacionados con procesos efusivos en niveles someros del sistema volcánico.

Durante el año 2021, la actividad eruptiva del volcán Sabancaya continuó siendo dominada por explosiones de intensidad variable, asociadas al crecimiento y destrucción de domos en el cráter activo actual (Machacca et al., 2023). Entre febrero y mayo de 2021, mostró un incremento de explosiones y el inicio de una nueva fase eruptiva, con un promedio de aproximadamente 42 explosiones por día (Fig. 1a). Asimismo, durante ese período los intervalos medios de reposo fueron de alrededor de 23 minutos y la energía de las explosiones fluctuó entre 0.01 MJ y 15 MJ. Dicha intensificación estuvo asociada con una notable deformación del flanco norte, registrada a través de datos GNSS, lo que indica la inyección somera de magma (Machacca et al., 2023). Luego, en junio de 2021, se observó un período de destrucción y hundimiento de domo, acompañado de una disminución abrupta tanto en la energía como en el número de explosiones diarias, con un promedio de 6 eventos por día. Este patrón observado en 2021 refuerza la correlación entre los pulsos de actividad efusiva, el crecimiento/colapso del domo y las fluctuaciones en el número y energía de las explosiones del volcán Sabancaya, mediados por procesos hidrotermales someros asociados.

En resumen, durante los años 2019 y 2021, se inventarió un total de 1343 explosiones en superficie con su respectivo tiempo de inicio, dirección de dispersión y altura de columna máxima. En dicho período, la columna de gases y ceniza alcanzo alturas de hasta 4.3 km sobre el cráter y elevaciones promedio de

3 km sobre la cima del volcán (Fig.1b). Este estudio utilizará toda esta información, para tratar de mejorar las caracterizaciones realizadas hasta ahora de manera manual.




Figura 1. Evolución temporal preliminar de a) la actividad magmática del volcán Sabancaya (explosiones y sismos LP) y b) la altura máxima de columnas eruptivas (representativas) caracterizadas manualmente, para el periodo enero 2019 y diciembre 2021.

### 3. METODOLOGÍA Y DATOS


Como se mencionó al inicio, el principal interés a corto o mediano plazo fue crear un sistema multiparamétrico que utiliza señales sísmicas e imágenes visuales para la emisión de alertas por actividad volcánica, que optimice capacidades de monitorización y toma de decisiones en tiempo casi real. Para ello, se centró en identificar los eventos explosivos del volcán Sabancaya a través de técnicas de inteligencia artificial, como una herramienta de apoyo para especialistas y autoridades, para advertir la ocurrencia de actividad volcánica inminente en caso de emergencia. El sistema se compone de cuatro módulos:

- Subsistema de tratamiento de imágenes: Detecta la presencia de una pluma de ceniza volcánica utilizando datos de videocámaras del volcán Sabancaya.
- Subsistema de detección y reconocimiento de sismos: Identifica señales sísmicas relacionadas con eventos explosivos del volcán Sabancaya de forma automática.
- Modelo multiparamétrico: Combina los resultados de los subsistemas anteriores para validar, confirmar y caracterizar eventos explosivos en tiempo casi real.
- Subsistema de envío de alertas: Recolecta datos visuales y meteorológicos para modelar la dinámica de una pluma eruptiva y su afectación.

#### 3.1. Análisis de imágenes

**Recopilación de imágenes:** Se recolectaron imágenes de 1,343 episodios explosivos capturados por la red de cámaras de videovigilancia ubicadas en el volcán Sabancaya y operadas por el Instituto Geofísico del Perú (IGP), durante

los años 2019 al 2021. Estas cámaras, denominadas SBYA, CAJ y MUCU, se encuentran a 31.8 km al NE, 11.1 km al SE y 9.2 km al NO del cráter actual, respectivamente (Fig. 2). Las cámaras son del modelo CCFC de la marca *Cambell Scientific*, con una resolución de 960 x 1280 píxeles y una velocidad de captura de 1 imagen cada 60 segundos. Los videos utilizados para cada episodio eruptivo tenían una secuencia máxima de 12 fotogramas.



**Figura 2.** Mapa satelital del complejo volcánico Ampato-Sabancaya (ASVC) y su entorno, que muestra la actividad volcánica reciente y los elementos expuestos a la caída de cenizas volcánicas. Los triángulos negros representan los sensores sísmicos y los triángulos de color azul indican la posición de cámaras de video + sensor sísmico, que forman parte de la red de vigilancia permanente del volcán Sabancaya. Se utilizaron las estaciones SAB y SBYA para recopilar datos sísmicos e imágenes visuales entre 2019 y 2021.

**Creación de máscaras:** Se creó una primera base de datos que incluyó 16116 imágenes de la videocámara SBYA. Posteriormente, se eliminaron imágenes defectuosas, repetidas o cubiertas por nubes en más del 70% de la imagen. Esto permitió obtener una segunda base de datos depurada de 3101 imágenes que se utilizaron luego para la creación de máscaras digitales de la región que

rodea exclusivamente la pluma de ceniza. Una máscara indica la pertenencia de cada píxel a una categoría específica, en nuestro caso ceniza.

Estas máscaras fueron etiquetadas como clase "ASH" para los píxeles de ceniza y clase "FONDO" para el fondo de la imagen sin ceniza. Finalmente, la base de datos depurada se dividió estratégicamente en tres partes: 80% para el entrenamiento, 10% para la validación del entrenamiento y 10% para la evaluación de la generalización del modelo.

**Segmentación semántica:** La segmentación automática de imágenes ha sido fundamental en la vulcanología y otras áreas científicas. En particular, la segmentación semántica basada en Redes Neuronales Convolucionales (CNNs) ha demostrado ventajas significativas en términos de resolución a nivel de píxel y eficiencia computacional (Wilkes et al., 2022). Uno de los modelos destacados en este campo es la red U-Net, que ofrece una alta velocidad y precisión en el procesamiento de datos incluso con pocos datos de entrenamiento y sin necesidad de entrenamiento previo (Ronneberger, 2015). La arquitectura de U-Net consta de tres componentes principales: el codificador, el *bottleneck* y el decodificador. El codificador captura el contenido de la imagen a través de capas de convolución y agrupación máxima, mientras que el *bottleneck* aumenta gradualmente el tamaño de la imagen reducida mediante convoluciones ascendentes y convoluciones transpuestas para recuperar la resolución espacial perdida. La fase de decodificación reconstruye la imagen segmentada utilizando convoluciones transpuestas y asegura una segmentación precisa de las estructuras en la imagen mediante la combinación eficiente de contexto global y local.

En este estudio, se utilizó la arquitectura U-Net con tres niveles de profundidad para la segmentación automática de imágenes. Durante la etapa de codificación, se aplicaron máscaras de convolución de 3x3 seguidas de funciones de activación no lineales (ReLU) para introducir no linealidad al modelo. En la etapa de *upsampling*, se recuperó progresivamente la resolución

espacial perdida mediante el uso de convoluciones transpuestas. Esta estrategia de contracción-expansión permite que la red combine de manera eficiente el contexto global y local, facilitando la segmentación precisa de las estructuras en la imagen.

**Evaluación del modelo:** La evaluación de los modelos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), para la segmentación semántica requiere el uso de métricas cuantitativas adecuadas que comparen las predicciones del modelo a nivel de píxel con las etiquetas manuales o "*ground truths*" de las imágenes (Ilglovikov et al., 2018). Durante el entrenamiento supervisado, una métrica fundamental es la función de pérdida (*loss*), que el modelo optimiza mediante algoritmos de descenso de gradiente para reducir los errores en la clasificación de píxeles. Las métricas más comunes utilizadas son la pérdida de entropía cruzada (*crossentropy loss*) y la pérdida de Intersección sobre Unión (IoU) (Wilkes et al., 2022).

Para evaluar el rendimiento del modelo se utiliza la precisión global (*Accuracy*), la cual se calcula como el porcentaje de píxeles correctamente clasificados como pluma o no pluma. El IoU que compara la superposición espacial entre la región segmentada predicha y la región real, siendo más robusto frente a desequilibrios en el número de píxeles (Rahman & Wang, 2016). Por otro lado, el coeficiente de Dice cuantifica la similitud de localización (Tabla 1).

Estas métricas se derivan de una matriz de confusión que incluye verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN). Valores cercanos a 1 en *Accuracy*, IoU y coeficiente Dice indican una alta coincidencia espacial entre las máscaras de segmentación predichas y las reales. Con este enfoque riguroso, tanto cuantitativo como cualitativo, se estima la utilidad del modelo en aplicaciones reales.

**Tabla 1.- Descripción de las métricas de evaluación.** Verdaderos positivos (TP): instancias que son positivas y son clasificadas como positivas. Falsos positivos (FP): instancias que son negativas, pero son clasificadas como positivas. Falsos negativos (FN): instancias que son positivas, pero son clasificadas como negativas. Verdaderos negativos (TN): instancias que son negativas y son clasificadas correctamente como negativas.

| Métrica                                | Definición                                                                                                                        | Formula                                                                           |
|----------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|
| Precision                              | Predicciones positivas correctas divididas por todas las predicciones positivas.                                                  | $\frac{TP}{TP + FP}$                                                              |
| Recall/ Sensitivity                    | Predicciones positivas correctas divididas por todas las muestras positivas.                                                      | $\frac{TP}{TP + FN}$                                                              |
| Specificity                            | Predicciones negativas correctas divididas por todas las muestras negativas.                                                      | $\frac{TN}{TN + FP}$                                                              |
| Accuracy (ACC)                         | Proporción de predicciones correctas entre todas las muestras.                                                                    | $\frac{TP + TN}{TP + FP + TN + FN}$                                               |
| Balanced Accuracy (BACC)               | Media del Recall y especificidad, es decir, precisión media por clase.                                                            | $0.5 \left( \frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right)$                      |
| Matthews Correlation Coefficient (MCC) | Mide la correlación de las clases verdaderas con las etiquetas predichas.                                                         | $\frac{TP \times TN + FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$ |
| Dice Coefficient                       | Mide la similitud entre el área de la máscara de segmentación predicha por el modelo y el área de la máscara real (ground truth). | $\frac{TP}{TP + \frac{1}{2}(FP + FN)}$                                            |
| IoU Score                              | Mide el solapamiento entre las áreas predichas por el modelo y las áreas reales (ground truth).                                   | $\frac{TP}{TP + FP + FN}$                                                         |

**Cálculo de parámetros de la pluma de cenizas:** La determinación de parámetros geométricos y dinámicos de una pluma eruptiva, como su altura, velocidad de ascenso y dispersión, es fundamental para caracterizar una erupción volcánica y estimar los peligros asociados.

Una vez aislada la pluma en los cuadros de video, en base a lo antes señalado. El resultado es una máscara binaria de píxeles correspondientes a la pluma volcánica. Luego, se aplica una transformación geométrica basada en las características de la cámara y su ubicación para pasar de un sistema de

coordenadas en píxeles a metros (Apéndice 2). Esto permite determinar la altura máxima de la columna volcánica ( $H_{max}$ ) tomando como referencia la posición del píxel superior de la máscara en cada cuadro (Simionato et al., 2022; Wilkes et al., 2022).

Luego, la velocidad de ascenso vertical instantánea de la pluma se calcula dividiendo la diferencia de altura entre cuadros consecutivos por el tiempo transcurrido entre ellos (Simionato et al., 2022; Wilkes et al., 2022). Adicionalmente, una velocidad de ascenso promedio se puede obtener con la altura máxima acumulada hasta el cuadro actual dividida por el tiempo total desde el inicio de la erupción (Simionato et al., 2022). Comparando estas mediciones con estudios previos se puede validar la efectividad de las metodologías aplicadas.

Finalmente, para determinar la dirección de dispersión de la ceniza emitida por el volcán Sabancaya, se utilizó un método basado en el enfoque del punto medio (Wilkes et al., 2022). Este método consiste en calcular el centro de la pluma volcánica y dividirla en dos secciones. Luego, se traza una línea que une los puntos medios de cada sección para determinar la dirección aproximada del flujo. Este proceso se puede repetir de manera iterativa para obtener una estimación más precisa. Es importante destacar que este método requiere una buena segmentación de la pluma y funciona mejor cuando hay un flujo direccional claro. Además, puede aplicarse tanto en fotografías como en secuencias de video.

Durante el desarrollo de la pluma de cenizas, se evaluó la dirección predominante del viento sobre la cual se dispersa. Para ello, se dividió la imagen de la cámara SBYA en ocho secciones equidistantes alrededor del centro del cráter (norte, noreste, este, sureste, sur, suroeste, oeste y noroeste). Se comparó la presencia de ceniza en cada sección para determinar la dirección predominante (Fig. 3b). En casos donde no fue posible determinar claramente la dirección, se utilizó la cámara MUCU. Esta cámara dividió la

imagen en dos secciones (derecha e izquierda) para obtener información adicional (Fig. 3c). Es importante tener en cuenta que la dirección de la pluma puede verse afectada por la naturaleza bidimensional de las imágenes. Por eso, en casos en los que la dirección sea sur, suroeste u oeste, se utilizó la cámara MUCU para estimar si la pluma se orientaba hacia la cámara o en dirección contraria. Esta combinación de información de ambas cámaras permitió obtener una elección más precisa de la dirección de propagación de la dispersión de ceniza de la pluma volcánica (Fig. 3a).

### 3.2. Análisis de datos sísmicos

**Mecanismo de detección y segmentación de eventos:** La detección sistemática de eventos sísmicos es crucial para un monitoreo efectivo en tiempo real. En sismología, el algoritmo STA/LTA (Short-Term Average/Long-Term Average) es comúnmente utilizado para la detección de eventos a través de redes sísmicas permanentes (Havskov & Alguacil, 2015). Este método se basa en la relación entre la amplitud promedio a corto plazo (STA) y la amplitud promedio a largo plazo (LTA). La relación STA/LTA se compara con un umbral de detección y si se supera durante un tiempo determinado, se considera que se ha detectado un evento sísmico.

En el contexto de eventos sísmicos de origen volcánico, como explosiones y demás sismos volcánicos y no volcánicos, el método STA/LTA también se utiliza ampliamente (Ibs-von Seht, 2008; Vassallo et al., 2012; Rajaeitabrizi et al., 2020; y McKee et al., 2022). Para su aplicación, se seleccionan filtros de activación y se configuran parámetros específicos según el tipo de evento y las características del ruido sísmico en el sitio (Trnkoczy, 2009). Por ejemplo, en el volcán Sabancaya se utilizó un STA de 3 segundos y un LTA de 15 segundos, con umbrales de activación y desactivación establecidos en  $R = 2$  y  $R = 1,5$  respectivamente. Además, se implementó una LTA congelada para evitar una detección prematura y asegurar una estimación precisa de la duración del evento. A partir de este proceso, se inicia el sistema propuesto.




Figura 3. Metodología usada para estimar la dirección de la pluma. (a) Esquema general que muestra la ubicación de la cámara principal y secundaria respecto al volcán Sabancaya. En color naranja se observa la vista noroeste respecto a la cámara principal, en verde la vista oeste y norte, en amarillo la vista suroeste y noreste, en azul la vista sur y este, y en negro la vista sureste respecto a la cámara principal. (b) Muestra la división en la imagen de la cámara principal (SBYA) en ángulos equidistantes alrededor del centro de la imagen en ocho secciones (norte, noreste, este, sureste, sur, suroeste, oeste y noroeste), para determinar la dirección de dispersión de la columna eruptiva. La imagen (c) muestra la división realizada en la cámara secundaria (MUCU) para determinar si la pluma se acerca o se aleja de la cámara principal (SBYA).

**Recolección y preprocesamiento:** La recolección de muestras representativas de sismos fue realizada por un sismólogo especialista del IGP. Ello, con la finalidad de evitar la subjetividad y sesgo del operador en turno y que, siguiendo un mismo criterio, se logre etiquetar, de manera correcta, los eventos sismo-volcánicos registrados en la componente vertical de la estación SAB (sismómetro Güralp 40T de 30 segundos, a 100 Hz). Dicha estación es la referente del volcán debido a su cercanía al cráter (3 km en dirección del flanco SE del volcán, Fig. 2a) y en funcionamiento, es la que mejor operó durante el periodo de estudio, con un 84% de datos disponibles entre los años 2019-2021.

En el volcán Sabancaya se reconocen 10 tipos de señales sísmicas (Machaca et al., 2022), pero durante el protocolo de análisis diario solo se pueden distinguir de manera directa seis de ellas: Largo Periodo (LP), Explosión (EXP), Volcano-Tectónico Distal (VTD), Tremor Espasmódico (TRE), Tremor Armónico (TRA) y Lahar (LAH). Asimismo, destacan otros dos tipos de señales que no están relacionadas con la actividad volcánica, pero ocurren todos los días y que corresponden a sismos tectónicos (TEC) y eventos raros o ruido local (GAR).

La sismicidad predominante observada en el volcán Sabancaya corresponde a eventos tipo LP y EXP. Así también, ocurren episodios de tipo tremor (TRE y TRA) que, a diferencia de los dos primeros, poseen una amplitud y duración sostenida en el tiempo. En frecuencia, los 4 concentran su energía en una banda de 0.5 Hz-2 Hz. Sobre su origen, todos los eventos antes mencionados guardan relación directa con el movimiento de fluidos en el interior de los conductos volcánicos (acumulación y ascenso de magma), así como en el exterior del volcán Sabancaya (formación de domos, emisiones de cenizas y gases volcánicos).

Durante el periodo de análisis, se implementó una base de datos sísmicos con 6869 muestras notables, de las cuales un 23% corresponde a eventos LP1, un 21% son eventos TEC, un 20% son eventos EXP, un 19% son eventos VTD, un 10% son eventos GAR y en menor proporción (2%) lo conforman los eventos TRE, TRA y LAH (Fig. 4a-h). Son 8 clases en total y como se aprecia, es una base de datos desbalanceada (Fig. 4i). Luego cada observación fue normalizada en energía, frecuencia y discretizadas en el tiempo. En energía se aplicaron correcciones a la señal como respuesta instrumental y en frecuencia se aplicó un filtro pasa banda Butterworth de 4° orden con frecuencias de corte normalizadas entre 1 Hz-15 Hz, donde mejor se concentra la energía de los sismos del volcán Sabancaya.

**Selección de características:** Varios autores han destacado la posibilidad de utilizar una amplia gama de características sísmicas, incluso más de cientos, al representar una señal sismo-volcánica a través de diferentes técnicas de aprendizaje automático (Malfante et al., 2018a; Malfante et al., 2018b; Lara et al., 2020).

En este estudio, después de revisar propuestas anteriores (Malfante et al., 2018a; Rey-Devesa et al., 2023) se seleccionó 27 características (Apéndice 1). Estas características se derivan de la forma de onda y el espectro de potencia de la señal. Incluyen parámetros como duración y energía (Tucker & Brown, 2005), que proporcionan información estadística básica de las señales, en el dominio del tiempo. También se emplearon el índice de frecuencia, relación de ataque, relación de decaimiento y coeficientes cepstrales (Álvarez et al., 2012) para codificar propiedades espectrales y temporales fundamentales. Además, se describe la distribución de amplitudes mediante parámetros estadísticos como media, desviación estándar, asimetría, curtosis, índice de energía central y ancho de banda RMS (Tucker & Brown, 2005). Luego, se cuantifica la complejidad espectral mediante entropía, brillo, entropía de Shannon y entropía de Rényi. Estas métricas permiten evaluar la variabilidad y la diversidad de frecuencias presentes en la señal (Esmaili et al., 2004; y Huang & Zhang, 2009). Por último, se calculan los coeficientes de predicción lineal


(LPC) para modelar el contenido en frecuencias de la señal (Malfante et al., 2018b).

**Selección del modelo:** En los últimos años, se han desarrollado métodos de Deep Learning para la clasificación supervisada de señales sismo-volcánicas, como las Redes Neuronales Convolucionales (CNN) y las Redes Neuronales Recurrentes (RNN) (Titos et al. 2019; Canário et al. 2020). Sin embargo, dichas arquitecturas suelen requerir más capacidad de cómputo, estudios recientes demuestran que configuraciones optimizadas de CNN y RNN pueden lograr una alta precisión sin necesidad de utilizar plataformas de alto rendimiento.

Por otro lado, entre los métodos clásicos de aprendizaje supervisado más utilizados para esta tarea se encuentran las Máquinas de Vectores de Soporte (SVM), los Bosques Aleatorios (RF), el Perceptrón Multicapa (MLP) y métodos basados en conjuntos de máquinas de aprendizaje (por ejemplo. Hassan AitLaasri et al., 2013; Hibert et al. 2017; Malfante et al. 2018b; Orozco-Alzate et al., 2019; Falcin et al., 2021). Estos modelos permiten una implementación rápida a partir de bases de datos, incluso en casos desbalanceados, y logran un buen rendimiento con un bajo consumo de recursos computacionales. En este trabajo, empleamos los cuatro métodos antes mencionados, dos de manera individual (SVM y MLP) y dos como conjuntos de máquinas de aprendizaje (RF y CatBoost). Los 4 métodos ofrecen ventajas en precisión y robustez que superan las deficiencias de los sistemas de clasificación tradicionales.

**Entrenamiento del modelo:** Se consideraron 4 algoritmos en la etapa de clasificación de eventos sísmicos, con el objetivo de seleccionar el que ofrece mejores resultados. En todos los casos, se utilizó una base de datos balanceada mediante el uso de técnicas de sobre muestreo, como el SMOTE (*Synthetic Minority Oversampling Technique*) (Chawla et al., 2002). Los hiperparámetros de cada algoritmo se validaron utilizando un *5-fold Cross Validation*. La base

de datos se dividió en un 70% para entrenamiento y un 30% para pruebas. La validación de los hiperparámetros se llevó a cabo utilizando el subconjunto de datos de entrenamiento.



**Figura 4.** Eventos sísmicos más comunes registrados en el volcán Sabancaya entre 2019 y 2021. Para cada tipo de evento, se representa (en azul) la forma de onda, junto con su espectro de potencia y espectrograma. Los ejemplos corresponden a: (a) explosiones (EXP), asociadas a procesos violentos de fragmentación del magma; (b) eventos de periodo largo (LP1), relacionados con inestabilidades de fluidos dentro de los conductos volcánicos; (c) eventos volcano-tectónicos distales (VTD), que indican fractura de rocas frágiles debido a la deformación del volcán; (d) señales de tremor (TRE), vinculadas a una actividad magmática/hidrotermal sostenida; (e) tremores armónicos (TRA), que indican resonancias de cavidades llenas de fluidos; (f) lahares superficiales (LAH), asociados a flujos de sedimentos-agua en los flancos escarpados; (g) terremotos tectónicos regionales (TEC); y (h) transitorios ruidosos muy locales (GAR). Para resaltar sus bandas de frecuencia dominantes, todas las formas de onda se filtraron con paso de banda entre 0.5 y 15 Hz antes del análisis. Por último, (i) muestra la distribución de muestras por tipo de evento, donde se puede notar el carácter desbalanceado de las observaciones.

**Validación del modelo:** El uso de métricas apropiadas para evaluar las prestaciones de los resultados de los modelos entrenados es un gran desafío si utilizamos conjuntos de datos desbalanceados. Las medidas de clasificación

utilizadas en este trabajo se muestran en la Tabla 1. El más conocido de ellos es la accuracy (ACC), una fracción de elementos correctamente clasificados. Se sabe que ACC es sesgada hacia la clase mayoritaria, por lo que no es adecuada para problemas de datos desbalanceados. Para superar esto, Balanced Accuracy (BACC) vuelve a ponderar los términos para tratar todas las clases por igual. El coeficiente de correlación de Matthews (MCC), que es el coeficiente de correlación de Pearson entre las clases verdaderas y las predichas en problemas de clasificación binaria, es otra métrica utilizada en problemas con datos desbalanceados. Para el caso multiclase, se calcula la covarianza de cada clase y los valores promedio se utilizan para calcular el coeficiente de correlación (Gösgens et al., 2022).

### 3.3. Datos meteorológicos

Con relación a este aspecto, se planteó la siguiente hipótesis: "Si 27 características de la señal sísmica pueden predecir la ocurrencia de una explosión volcánica, también se podrían predecir sus dimensiones en superficie". Con este propósito, se dividió el conjunto de 1,343 eventos EXP en dos grupos, según la altura máxima de la columna eruptiva ( $H_{max}$ ) alcanzada por cada evento. Se estableció un límite máximo de 3 km sobre el cráter actual, que permitió clasificar los datos en plumas de baja (LC) y alta (HC) columna eruptiva. Este umbral se estableció siguiendo un protocolo de seguridad para la aviación civil (nacional). Si una pluma de cenizas supera dicho límite, se emite de inmediato una alerta de dispersión de cenizas (VONA), que es enviada oficialmente por el IGP a la Corporación Peruana de Aeropuertos y Aviación Comercial (CORPAC) y al Centro de Aviso de Cenizas Volcánicas de Buenos Aires (VAAC Bs As).

Además de las 27 características utilizadas para representar las señales sísmicas del volcán Sabancaya, especialmente las relacionadas con las explosiones, se exploró la posibilidad de utilizar otro tipo de información disponible, que no estuviera relacionada con señales ni imágenes, pero que

tuviera relevancia para la actividad superficial del volcán. Como alternativa viable, se recurrió a la base de datos histórica de variables meteorológicas del Sistema Global de Asimilación de Datos (GDAS/FNL) para la zona del volcán Sabancaya, que coincidieran con la fecha y hora de inicio de registro de las 1,343 explosiones volcánicas.

El sistema GDAS/FNL consiste en análisis y pronósticos con una resolución horizontal de  $0.25^\circ$  y 26 niveles verticales. La combinación óptima de las observaciones con el modelo numérico de la atmósfera se realiza mediante un proceso llamado asimilación de datos. Este proceso consiste en utilizar toda la información disponible para determinar, de manera más precisa posible, el estado de la atmósfera (Talagrand, 1997). Se insertan observaciones en el espacio del modelo para generar mejores condiciones iniciales para el siguiente ciclo de pronóstico del tiempo, lo que mejora la precisión de los pronósticos meteorológicos. Este proceso se lleva a cabo cada 6 horas, generando nuevos ciclos de pronóstico a las 00:00, 06:00, 12:00 y 18:00 UTC. El GDAS/FNL contiene variables meteorológicas tridimensionales para cada instante de tiempo, como presión, temperatura, altura geopotencial y las componentes: zonal ( $u$ ) y meridional ( $v$ ) del viento.

La razón de utilizar datos meteorológicos se debe a que las plumas volcánicas están influenciadas por las condiciones atmosféricas y los vientos circundantes. Cuando la velocidad de ascenso de la pluma es menor que la velocidad del viento, la pluma se inclina. Por otro lado, cuando la velocidad de ascenso de la pluma es mayor, se forma una columna convectiva subvertical que se extiende en el nivel de flotabilidad neutra como una corriente lateral (Bonadonna & Phillips, 2003). La interacción entre la pluma y los vientos atmosféricos afecta la altura máxima que puede alcanzar. Asimismo, las plumas volcánicas también son influenciadas por la estabilidad de la atmósfera, la cual está determinada por la estructura vertical de la temperatura y la humedad ambiente. Las variaciones en la estabilidad atmosférica pueden cambiar la altura

máxima de una columna eruptiva, incluso con una tasa de erupción constante (Carey et al., 2015).

Por ello, esta nueva base de datos incluye una amplia gama de variables meteorológicas derivadas de datos observacionales y modelados, tomadas a diferentes niveles de la atmósfera. En este estudio, se utilizaron las lecturas de viento zonal ( $u$ ), viento meridional ( $v$ ), velocidad del viento ( $V_{ms}$ ), dirección del viento ( $D$ ) y temperatura ( $T$ ), tomadas a una altitud cercana a los 3 km sobre el cráter del volcán. A modo de referencia, se puede consultar la Tabla 2 para obtener más detalles sobre las variables meteorológicas utilizadas y su correspondiente unidad física.

Tabla 2.- Características derivadas de datos sísmicos y meteorológicos.

| Parámetros (Features)                    | Unidades       | Descripción                                                                                                                                                                                                                       |
|------------------------------------------|----------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Componente zonal del viento ( $u$ )      | $m.s^{-1}$     | La componente del viento se refiere a la parte del viento orientada en dirección este-oeste, a lo largo de las líneas de longitud.                                                                                                |
| Componente meridional del viento ( $v$ ) | $m.s^{-1}$     | La componente del viento se refiere a la parte del viento orientada en dirección norte-sur, a lo largo de las líneas de latitud.                                                                                                  |
| Velocidad del viento ( $V_{ms}$ )        | $m.s^{-1}$     | Es la velocidad a la que se mueve el aire en un punto concreto de la atmósfera.                                                                                                                                                   |
| Dirección del viento ( $D$ )             | <i>Degrees</i> | La dirección de la que procede el viento. Se suele medir en grados, con 360 grados representando un círculo completo, donde 0 grados corresponden al norte verdadero, 90 grados al este, 180 grados al sur y 270 grados al oeste. |
| Temperatura ( $T$ )                      | $K$            | El uso de la escala Kelvin para medir la temperatura a diferentes altitudes se basa en las ventajas de la escala Kelvin en aplicaciones científicas y termodinámicas.                                                             |

Con base en esta información, se construyó un conjunto de datos compuesto por 1,209 muestras etiquetadas como "LC" y 135 muestras etiquetadas como "HC". A continuación, se organizó una matriz de características con 1,343 filas y 33 columnas, que incluyen las 27 características de la señal sísmica y los 5 parámetros meteorológicos. La última columna corresponde a una variable categórica utilizada para resolver un problema de clasificación binaria (HC o LC), empleando las mismas técnicas de ML utilizadas anteriormente.

## 4. RESULTADOS

### 4.1. Segmentación de imágenes

En un primer momento, se planteo evaluar la arquitectura U-Net propuesta y su capacidad de aislar de manera correcta los píxeles de ceniza volcánica mediante imágenes visibles del volcán Sabancaya.

Para lograr ello, se empleó una variedad de métricas de evaluación, como la precisión (*accuracy*), que indica la precisión del modelo para predecir correctamente los píxeles de una pluma de ceniza. Además, se utilizó el índice de Jaccard, que indica el grado de similitud entre las máscaras predichas y las de referencia. Asimismo, el coeficiente de Dice, que busca maximizar la coincidencia entre la región segmentada automáticamente y la región etiquetada manualmente. Dichas métricas se evaluaron a partir de los datos de validación.

En la tabla 3, el modelo implementado logró un puntaje promedio de Dice de 0.89 y una precisión de segmentación de píxeles del 98.85% sobre el conjunto de entrenamiento, demostrando capacidad de aprender los patrones característicos de las plumas volcánicas. Sobre la partición independiente de prueba, estas métricas se conservaron en niveles adecuados (Dice 0.88, precisión 98.67%), denotando efectiva generalización frente a nuevos datos.

Tabla 3. Métricas de evaluación del modelo de segmentación implementado.

|            | Loss (%) | Precision (%) | Dice coefficient (%) | IoU Score (%) |
|------------|----------|---------------|----------------------|---------------|
| Training   | 1.14     | 98.85         | 89.34                | 80.81         |
| Validation | 1.32     | 98.83         | 88.75                | 79.82         |
| Test       | 2.02     | 98.67         | 87.51                | 77.90         |

Los resultados cuantitativos actuales evidencian la validez de la propuesta metodológica basada en redes neuronales convolucionales para la segmentación precisa de plumas de ceniza en contextos vulcanológicos específicos.

Con el modelo entrenado, se han realizado tres experimentos en operación. El primero (Fig. 5a), el 9 de enero de 2023 a las 11:32:30 UTC el Sabancaya emitió una pluma volcánica en condiciones ideales, como se muestra en la Fig. 4a. La predicción coincidió en un 99% con las imágenes de las cámaras MUCU, CAJ y SBYA. Sin embargo, en CAJ, la coincidencia fue solo del 39%, posiblemente debido a un efecto óptico causado por la posición del sol, lo que generó confusión entre la pluma volcánica y una nube convencional. El segundo (Fig. 5b), el 11 de enero de 2023 a las 18:36:31 UTC se detectó otra pluma volcánica con presencia de nubes, como se muestra en la Fig. 5b. La predicción coincidió en un 95% con la cámara Chivay, pero la coincidencia disminuyó al 60% en MUCU, debido al ocultamiento parcial de nubes. Nuevamente, en CAJ la coincidencia fue muy baja, solo del 15%, posiblemente debido a una confusión óptica con nubes debido a la luz solar incidente. Mientras que el tercero (Fig. 5c) muestra una pluma registrada el 12 de febrero de 2023 a las 21:36:30 UTC en condiciones de alta nubosidad. A pesar de la presencia de nubes, las condiciones de luz fueron las ideales, lo que permitió una clara distinción de la pluma desde CAJ con un 90% de coincidencia.

#### **4.2. Caracterización de la pluma volcánica**

Considerando una buena visibilidad en la zona del volcán y la disponibilidad de imágenes durante el día, el sistema tiene la capacidad de obtener de manera sistemática y cuantitativa parámetros como la altura máxima ( $H_{max}$ ) y la tasa de crecimiento de las plumas eruptivas del volcán Sabancaya. Para demostrar esto, se puso a prueba el sistema propuesto utilizando 1343 mediciones de altura de columna eruptiva máxima reportadas por el IGP entre los años 2019 y 2021. Estas plumas tenían una altura mínima de 150 m y una máxima de aproximadamente 4200 m, por encima del cráter del volcán.




Figura 5: Comparación de plumas y la capacidad del modelo para predecir los píxeles que conforman la columna de ceniza en tres cámaras. (a) la capacidad del modelo para predecir una pluma en condiciones ideales. (b) la capacidad del modelo para predecir una pluma en condiciones no ideales. (c) la capacidad del modelo para predecir una pluma en condiciones críticas.

Para evaluar la exactitud y precisión de nuestros resultados, se compararon las mediciones de altura de columna automáticas ( $H_a$ ) con las mediciones realizadas por un operador experto ( $H_o$ ). Calculamos la diferencia absoluta entre estos valores ( $R = |H_o - H_a|$ ), a lo que llamamos "residuo" ( $R$ ). Además, utilizamos indicadores de exactitud y precisión como la media ( $\mu$ ) y la dispersión de los residuos ( $SD$ ).

En la Fig. 6a, se muestra un diagrama de correlación-dispersión entre los valores de  $H_o$  y  $H_a$ , con un índice de correlación  $r$  de 0.67, lo que indica una correlación positiva significativa ( $\pm 0.7$  a  $\pm 0.84$ ). En el histograma de la Fig. 6b, se observa un rango de residuos que va desde 9 m hasta 3422 m, con una media de 226 m y una desviación estándar de 471 m. Esto sugiere que, en promedio, las mediciones automáticas tienden a ser 226 m más altas que las observadas, y que las diferencias individuales tienden a variar alrededor de este valor en aproximadamente 471 m.




Figura 6: a) Diagrama de correlación-dispersión entre los valores de  $H_o$  y  $H_a$ , para un índice de correlación de 67% y b) histograma que muestra la distribución de los residuos obtenidos entre los valores observados y los obtenidos automáticamente, con una media de 226 m y una desviación estándar de 471 m.

La Fig. 7 a y b, presentamos la altura máxima de una pluma de cenizas registrada en una secuencia de fotogramas del volcán Sabancaya el 16 de septiembre de 2021 a las 12:19 (UTC), junto con su velocidad de ascenso entre imágenes sucesivas. Nuestra configuración aseguró que las plumas predichas por el sistema no se elevaran más allá del campo de visión de cada imagen, lo que nos permitió estimar la altura y velocidad de ascenso de manera más precisa. En este caso específico, la altura máxima de la pluma fue de aproximadamente 4200 m (por encima del cráter activo) y la velocidad de ascenso fue de 13 m/s. En general, las 310 plumas del volcán Sabancaya evaluadas presentaron velocidades que oscilaron entre 3 m/s y 27 m/s (Fig. 7c).

Para determinar la dirección de dispersión de cenizas, se requirió el registro simultáneo de eventos explosivos en al menos dos cámaras del volcán. Después del año 2021, se modificó el enfoque de las cámaras MUCU y CAJ. Para garantizar que la metodología funcione con datos más recientes, se utilizaron 111 eventos explosivos registrados fuera del período de análisis por las cámaras SBYA, MUCU y CAJ, entre enero y octubre de 2023.




Figura 7. a) Secuencia de imágenes de una explosión en el volcán Sabancaya el 16 de setiembre de 2021, desde las 12:22 hasta las 12:31 (UTC), con un  $H_{max}$  de  $\sim 4200$  m. b) Cálculo de la altura de la pluma en cada fotograma (línea azul) y la velocidad de ascenso (línea roja). La velocidad de ascenso es inicialmente relativamente estable y luego comienza a disminuir antes de extenderse más allá del campo de visión de la cámara.

En la Figura 8 se presentan los resultados de la estimación automática de la dirección de dispersión de cenizas (color morado) en comparación con los valores obtenidos por un operador experto (color naranja). Luego, la visualización en simultáneo de ambos conjuntos de datos direccionales (color marrón) revela una similitud del 58% entre los resultados de la dirección de dispersión de cenizas obtenidos mediante el modelo y la visualización del observador.

#### 4.3. Clasificación automática de señales sísmicas

Se propusieron 4 modelos para su entrenamiento y posterior evaluación de su desempeño al tratar de clasificar sistemáticamente 8 clases de sismos característicos del volcán Sabancaya. Haciendo especial énfasis en la detección y clasificación automática de explosiones (EXP), para fines del presente estudio.




Figura 8. Roseta de vientos para la validación de la dirección de dispersión de ceniza del volcán Sabancaya, durante el periodo entre enero a octubre de 2023, comparando los resultados obtenidos de manera manual (naranja) con los resultados obtenidos por el modelo de segmentación (morado); donde se observa un 58% de certeza (color marrón).

A tal efecto, se recopiló un total de 6869 trazas sísmicas registradas en el período de 2019-2021, abarcando diferentes tipos de eventos como explosiones (EXP), Largo Periodo (LP1), Volcano-Tectónico Distal (VTD), Tremor (TRE), Tremor Armónico (TRA) y Lahar (LAH). A partir de estas trazas sísmicas ampliadas, se extrajeron 27 atributos del dominio tiempo-frecuencia. Para asegurar un balance en la muestra, se aplicó la técnica de sobre muestreo SMOTE, generando 1300 muestras sintéticas adicionales de las clases minoritarias.

Con el conjunto de datos preparado, se implementaron cuatro algoritmos de clasificación supervisada: SVM MLP, RF y CatBoost. Se optimizaron los hiperparámetros de cada modelo utilizando una búsqueda de cuadrícula y validación cruzada de 5 particiones. El 30% restante de los datos (2061 sismos) se reservó como conjunto de prueba independiente para evaluar el rendimiento final de los modelos.

En general, los algoritmos presentados en la Tabla 4, muestran un buen desempeño de todos los modelos en términos de precisión total, ACC. CatBoost se destaca ligeramente con un valor promedio de 94.5%, aunque todos los modelos logran clasificar correctamente más del 92% de los casos. Además, el equilibrio de precisión entre las clases, BACC, se mantiene alto, especialmente para CatBoost con un valor promedio de 0.92, lo cual indica una buena capacidad de clasificación incluso en las categorías minoritarias. El coeficiente de correlación de Matthews (MCC), también confirma una correlación significativa entre las predicciones y las etiquetas reales, respaldando la confiabilidad global de los enfoques explorados.

*Tabla 4. Métricas de desempeño promedio y desviación estándar para cuatro modelos de clasificadores: Máquinas de Vectores de Soporte (SVM), Redes Neuronales Multicapa Perceptrón (MLP), Bosques Aleatorios (RF) y CatBoost. Las métricas fueron calculadas sobre el subconjunto de prueba independiente con 10 repeticiones. Las métricas reportadas incluyen la precisión total (ACC), precisión balanceada (BACC) y el coeficiente de correlación de Matthews (MCC).*

| Método   | ACC        | BACC       | MCC        |
|----------|------------|------------|------------|
| SVM      | 0.93±0.0   | 0.91±0.0   | 0.91±0.0   |
| MLP      | 0.93±0.004 | 0.90±0.012 | 0.92±0.005 |
| RF       | 0.94±0.003 | 0.91±0.010 | 0.93±0.004 |
| CatBoost | 0.95±0.004 | 0.92±0.010 | 0.93±0.005 |

Para una evaluación más detallada del desempeño de cada tipo de evento sísmico de interés, se presentan las matrices de confusión para los modelos RF y CatBoost en la Tabla 5 y 6. En general, se observa un rendimiento competitivo en la mayoría de las clases, con una precisión superior al 90% en LP1, VTD y algunas clases minoritarias como TRA. Sin embargo, se identifican algunas imprecisiones en la detección de explosiones (EXP), con falsos positivos en el rango del 6-7%. Además, las clases TRE y TRA muestran problemas de omisión con sensibilidades menores.

Al comparar los modelos, se observa que RF (Tabla 5) logra una sensibilidad promedio del 80% para las explosiones, pero aún confunde aproximadamente el 10% de los eventos reales de EXP con sismos tectónicos (TEC). Por otro lado, CatBoost (Tabla 6) eleva este indicador al 94%, lo que demuestra una mayor

capacidad para detectar explosiones superficiales sin generar falsos negativos. Además, según la matriz de CatBoost, ninguna explosión real es confundida con LP1 o TEC, lo cual confirma una mejor discriminación física de los procesos sísmicos.

Tabla 5. Matriz de confusión calculado con los datos de prueba para modelos generados con RF

| Random Forest             |     | Predicted Label |      |      |      |      |       |      |      | Accuracy (%) |
|---------------------------|-----|-----------------|------|------|------|------|-------|------|------|--------------|
|                           |     | EXP             | GAR  | LAH  | LP1  | TEC  | TRA   | TRE  | VTD  |              |
| True Label (ground truth) | EXP | 375             | 0    | 0    | 2    | 14   | 0     | 10   | 0    | 93.5         |
|                           | GAR | 0               | 186  | 6    | 8    | 2    | 0     | 0    | 2    | 91.2         |
|                           | LAH | 0               | 1    | 50   | 0    | 1    | 0     | 0    | 1    | 94.3         |
|                           | LP1 | 0               | 5    | 0    | 513  | 0    | 0     | 0    | 1    | 98.8         |
|                           | TEC | 15              | 3    | 0    | 2    | 420  | 0     | 5    | 4    | 93.5         |
|                           | TRA | 0               | 0    | 0    | 0    | 7    | 20    | 0    | 0    | 74.1         |
|                           | TRE | 5               | 1    | 2    | 0    | 4    | 0     | 35   | 0    | 74.5         |
|                           | VTD | 0               | 14   | 0    | 2    | 1    | 0     | 0    | 344  | 95.3         |
| Precision (%)             |     | 94.9            | 88.6 | 86.2 | 97.3 | 93.5 | 100.0 | 70.0 | 97.7 |              |
| Overall accuracy (%)      |     |                 |      |      |      |      |       |      |      | 94.3         |

Tabla 6: Matriz de confusión calculado con los datos de prueba para los modelos generados con Catboost.

| CatBoost                  |     | Predicted Label |      |      |      |      |       |      |      | Accuracy (%) |
|---------------------------|-----|-----------------|------|------|------|------|-------|------|------|--------------|
|                           |     | EXP             | GAR  | LAH  | LP1  | TEC  | TRA   | TRE  | VTD  |              |
| True Label (ground truth) | EXP | 376             | 0    | 0    | 3    | 11   | 0     | 11   | 0    | 93.8         |
|                           | GAR | 0               | 188  | 5    | 7    | 2    | 0     | 0    | 2    | 92.2         |
|                           | LAH | 0               | 1    | 50   | 0    | 1    | 0     | 0    | 1    | 94.3         |
|                           | LP1 | 0               | 6    | 0    | 512  | 0    | 0     | 0    | 1    | 98.7         |
|                           | TEC | 19              | 1    | 2    | 1    | 415  | 0     | 6    | 5    | 92.4         |
|                           | TRA | 1               | 0    | 0    | 0    | 5    | 21    | 0    | 0    | 77.8         |
|                           | TRE | 4               | 0    | 2    | 0    | 3    | 0     | 38   | 0    | 80.9         |
|                           | VTD | 0               | 10   | 0    | 2    | 2    | 0     | 0    | 347  | 96.1         |
| Precision (%)             |     | 94.0            | 91.3 | 84.7 | 97.5 | 94.5 | 100.0 | 69.1 | 97.5 |              |
| Recall (%)                |     | 93.8            | 92.2 | 94.3 | 98.7 | 92.4 | 77.8  | 80.9 | 96.1 |              |
| F1 Score (%)              |     | 93.9            | 91.7 | 89.3 | 98.1 | 93.5 | 87.5  | 74.5 | 96.8 |              |
| Overall accuracy (%)      |     |                 |      |      |      |      |       |      |      | 94.5         |

En cuanto al proceso de modelado, se analizaron las curvas de aprendizaje del modelo CatBoost. En la Fig. 9 se observa que el punto óptimo de detención ocurre alrededor de las 1000 iteraciones, donde la divergencia entre las curvas

de entrenamiento (train) y validación (val) es mínima. Esto indica un equilibrio razonable entre el subajuste (underfitting) y el sobreajuste (overfitting) del modelo. Además, la rápida convergencia de las curvas respalda la eficiencia computacional de CatBoost para su implementación en entornos de monitoreo sísmico continuo.

También se realizó un análisis del desempeño de las características empleadas al momento de evaluar los modelos propuestos, en este caso utilizando técnicas de permutación. En la Fig. 10 se comparan los rankings de importancia obtenidos por RF y CatBoost.

En ambos casos, se identificaron variables como la duración de la traza (dr), los coeficientes cepstrales CC3 y CC5 relacionados al espectro de potencia, y la energía en la banda 1-2 Hz (ci) como los más determinantes. El buen desempeño de estas variables confirma su utilidad discriminativa entre las diferentes tipologías sísmicas analizadas en el volcán Sabancaya.




Figura 9: Curva de aprendizaje del modelo CatBoost donde se puede notar como el algoritmo aprende optimizando la función de coste y sin tendencia al sobreajuste. Los parámetros fueron validados con validación cruzada y el entrenamiento se detiene cuando alcanza las 1000 iteraciones.




Figura: 10: Diagrama de barras donde se expresa la importancia que tiene cada una de las características en los algoritmos RF (a) y CatBoost (b)

#### 4.4 Caracterización de la pluma volcánica en condiciones adversas

Con el objetivo de investigar la factibilidad de estimar cualitativamente el tamaño de explosiones basado únicamente en el análisis en tiempo real de la firma sísmica asociada; se categorizaron 1343 eventos eruptivos del volcán Sabancaya con su correspondiente registro de actividad precursora.

En la Fig. 11 se muestra como las explosiones fueron divididas en dos clases según la altura de la columna eruptiva evidenciada en videos sincronizados: aquellas menores a 3 km sobre el cráter (clase LC, 1209 casos) y las mayores o iguales a dicho umbral (clase HC, 135 eventos). Si bien la distribución es marcadamente asimétrica, ambas categorías cuentan con suficientes casos como para capturar estadísticamente sus características distintivas durante la etapa de entrenamiento supervisado.

Inicialmente se implementaron cuatro algoritmos de clasificación estándar (SVM, MLP, RF y CatBoost) utilizando como predictores las 27 variables sísmicas extraídas previamente en este estudio. Posteriormente, se amplió la información de entrada incorporando 5 predictores meteorológicos adicionales provenientes

de un modelo numérico del tiempo, con el propósito de representar las condiciones ambientales imperantes durante cada episodio eruptivo registrado.




Figura 11: Histograma que muestra la distribución de datos de las categorías LC y HC.

El desempeño predictivo fue cuantificado mediante indicadores estándar para problemas de clasificación con distribuciones asimétricas de clases: la métrica de precisión balanceada, BACC, y el coeficiente de correlación de Matthews, MCC. Si bien los cuatro modelos exhibieron cierta capacidad de generalización, el algoritmo CatBoost evidenció una leve ventaja al momento de discriminar explosiones de distinto tamaño basado únicamente en los predictores sísmicos y meteorológicos provistos.

Tabla 7: Métricas de desempeño promedio y desviación estándar para cuatro clasificadores: Máquinas de Vectores de Soporte (SVM), Redes Neuronales Multicapa Perceptrón (MLP), Bosques Aleatorios (RF) y CatBoost. Las métricas fueron calculadas sobre el subconjunto de prueba independiente con 10 repeticiones. Las métricas reportadas incluyen la precisión total (ACC), precisión balanceada (BACC) y el coeficiente de correlación de Matthews (MCC).

| Método   | ACC              | BACC             | MCC              |
|----------|------------------|------------------|------------------|
| SVM      | $0.88 \pm 0.011$ | $0.60 \pm 0.027$ | $0.26 \pm 0.062$ |
| MLP      | $0.89 \pm 0.006$ | $0.69 \pm 0.028$ | $0.41 \pm 0.043$ |
| RF       | $0.90 \pm 0.016$ | $0.69 \pm 0.028$ | $0.42 \pm 0.038$ |
| CatBoost | $0.89 \pm 0.012$ | $0.73 \pm 0.034$ | $0.44 \pm 0.060$ |

Al analizar en detalle la matriz de confusión para CatBoost, se aprecia una adecuada tasa de detección de explosiones grandes (sensibilidad de 93%) pero con una moderada tasa de falsos positivos (25%), los cuales corresponden a eventos LC erróneamente categorizados como HC. Si bien este comportamiento podría optimizarse adaptando los umbrales de decisión, en aplicaciones orientadas a la alerta temprana usualmente se prefieren modelos más sensibles para detectar de manera confiable los eventos peligrosos (verdaderos HC en este caso), así se generen eventuales alarmas adicionales.

Tabla 8: Matriz de confusión calculado con los datos de prueba para los modelos generados con los algoritmos RF y CatBoost.

| Método:<br>RF    |       |     | Método<br>CatBoost |       |     |
|------------------|-------|-----|--------------------|-------|-----|
|                  | HC    | LC  |                    | HC    | LC  |
| HC               | 18    | 27  | HC                 | 20    | 25  |
| LC               | 17    | 340 | LC                 | 25    | 332 |
| Precision        | 0.926 |     | Precision          | 0.93  |     |
| Recall           | 0.952 |     | Recall             | 0.93  |     |
| F1 Score         | 0.939 |     | F1 Score           | 0.93  |     |
| Overall Acuraccy | 0.891 |     | Overall Acuraccy   | 0.876 |     |

## 5. DISCUSIÓN

### 5.1 Sismos asociados a explosiones de ceniza

Los resultados obtenidos en este estudio corroboran la efectividad de las técnicas de aprendizaje automático para la detección y clasificación automática de señales sísmicas del volcán Sabancaya, en especial, las asociadas a explosiones volcánicas (EXP).

En cuanto a la clasificación de sismos asociados a explosiones de ceniza, los modelos implementados lograron una precisión sobresaliente, superando el 94% en todos los casos. Específicamente, CatBoost alcanzó una precisión de 94.5%, incluso mayor que el 93.5% reportado previamente por Malfante et al. (2018) en explosiones del volcán Ubinas. Considerando la complejidad inherente de distinguir explosiones superficiales de otros eventos frecuentes en el registro sísmico, estos resultados son muy alentadores.

Un factor distintivo de nuestro estudio fue la incorporación de una etapa de sobre muestreo (SMOTE) para compensar la escasez inicial de casos positivos, como las explosiones. Esta estrategia sencilla probablemente contribuyó al incremento de la sensibilidad en la detección de explosiones con CatBoost, alcanzando un 93.8%, muy por encima del 59.8% logrado sin SMOTE por Malfante et al. (2018b). Se sugiere que investigaciones futuras en clasificación sísmica automática contemplen el balanceo previo de los conjuntos de datos cuando los eventos de interés, como explosiones o lahares, están subrepresentados (Malfante et al., 2018b).

Aunque el modelo CatBoost logró discriminar correctamente las explosiones de otros eventos, aún se observaron algunos falsos positivos (6-7%). Al respecto, se sugiere que la incorporación de atributos espectrales complementarios, como la pendiente espectral y la tasa de cruces por cero, podría reducir esta confusión

residual, tal como lo plantearon Malfante et al. (2018b) y Peixoto et al. (2021) en sus estudios sobre clasificación automática de señales sismo-volcánicas.

Mediante el análisis de importancia de características utilizadas en nuestro estudio, se encontró consistencia con trabajos previos (Malfante et al., 2018b; y Falcin et al., 2021) en cuanto a los atributos más determinantes para la separabilidad de las clases sísmicas, especialmente aquellos relacionados con el contenido espectral. Esto evidencia la relevancia de una selección adecuada de descriptores en este tipo de aplicaciones.

En conclusión, los modelos implementados ofrecen una alternativa prometedora para la identificación automatizada de explosiones y otros eventos críticos en escenarios de monitoreo volcánico. Con mejoras incrementales en su robustez y transportabilidad, se estimó factible su implementación operativa en centros vulcanológicos, lo que contribuiría a los sistemas de alerta temprana ante amenazas eruptivas.

## **5.2 Estimación del tamaño de columnas eruptivas**

La relación entre la altura de la pluma volcánica y las señales sísmicas es un tema de gran importancia, ya que implica comprender la actividad volcánica y los riesgos que conlleva. Existe una conexión entre la altura de la pluma volcánica y las señales sísmicas, ya que las erupciones volcánicas pueden generar actividad sísmica, lo cual puede servir como indicador de la intensidad y dinámica de la actividad volcánica. Sin embargo, es importante tener en cuenta que la relación exacta entre la altura de la pluma volcánica y las señales sísmicas puede variar debido a diversos factores, como el estilo eruptivo, la fase de erupción y las condiciones meteorológicas.

En cuanto a la estimación indirecta del tamaño de una explosión, se han propuesto diversos métodos que tratan de inferir la altura de las plumas de ceniza durante las explosiones, a partir de mediciones remotas del proceso eruptivo

mediante acústica o sensores sísmicos, entre otros. Uno de los más utilizados ha sido el desplazamiento reducido (DR), que relaciona la amplitud sísmica pico a pico con la altura de la pluma mediante una ley de potencia (McNutt, 1994). Otro enfoque consiste en correlacionar la energía sísmica radiada acumulada con el volumen o la masa de eyección (Kumagai et al., 2015). Sin embargo, estos métodos presentan la limitación de tener correlaciones débiles debido a la dispersión en los datos.

Recientemente se ha propuesto utilizar la amplitud de la fuente sísmica (ASL), estimada asumiendo una radiación isotrópica de ondas S, la cual es proporcional al flujo volumétrico de eyección (Mori & Kumagai, 2019). Este enfoque permite estimar la altura de la pluma mediante leyes empíricas de potencia y exponenciales. No obstante, estos métodos no son exportables y tienen incertidumbres de hasta 3 km en la estimación.

En este estudio, se exploró una metodología novedosa y relativamente sencilla. Consiste en utilizar los mismos predictores del dominio tiempo-frecuencia en la señal sísmica para clasificar los sismos de origen volcánico, especialmente aquellos relacionados con emisiones de ceniza, y que después de agruparlos según un tamaño de altura de columna referencial (3 km), entrenar modelos que puedan integrar datos sísmicos y meteorológicos para estimar o inferir el tamaño de una explosión en la superficie sin necesidad de revisar su registro visual.

Los resultados de este estudio demuestran la factibilidad de estimar cualitativamente el tamaño de las explosiones volcánicas en el Sabancaya basándose únicamente en el análisis en tiempo real de la actividad sísmica precursora y las condiciones meteorológicas imperantes. Si bien los cuatro algoritmos de clasificación implementados -SVM, MLP, RF y CatBoost- exhibieron cierto nivel de capacidad predictiva, CatBoost presentó una leve ventaja con una precisión balanceada de 0.73 y un coeficiente de Matthews de 0.44. Esto indica un desempeño moderado en la discriminación entre explosiones pequeñas y grandes. El análisis de la matriz de confusión resalta una adecuada tasa de

detección de eventos de gran magnitud, del 93%, aunque con una moderada tasa de falsos positivos del 25%. Este comportamiento es aceptable en el contexto de sistemas de alerta temprana, donde maximizar la sensibilidad para detectar eventos peligrosos es prioritario sobre minimizar falsas alarmas. Si bien se requiere investigación adicional para mejorar la precisión de los modelos, este primer acercamiento utilizando técnicas de aprendizaje automático es prometedor. Los predictores sísmicos y meteorológicos extraídos contienen información relevante sobre el proceso físico subyacente y permiten categorizar razonablemente bien explosiones de distinto tamaño.

Más allá de la discriminación cualitativa binaria de tamaños de columna alcanzada, los enfoques metodológicos desarrollados sentarían bases para investigaciones orientadas a pronósticos cuantitativos de altura de columna eruptiva y dispersión distal de cenizas.

### **5.3 Potencial para alerta temprana cuantitativa**

El sistema propuesto de detección explosiones volcánicas empleando imágenes de video del volcán Sabancaya para la alerta temprana, ha reproducido consistentemente un 86% de los datos estudiados sobre la altura de la columna eruptiva máxima ( $H_0$ ), reportados por el IGP durante el periodo 2019-2021. Es importante destacar que este sistema tiene la capacidad de detectar y caracterizar automáticamente la altura de la columna eruptiva máxima del volcán Sabancaya en diferentes condiciones atmosféricas, ya sea en un cielo despejado o con hasta un 25% de nubosidad, con una precisión de  $\pm 500$  m. Esta precisión se encuentra dentro del rango utilizado comúnmente por los observatorios vulcanólogos para caracterizar las plumas volcánicas, como se ha observado en el caso del volcán Etna en Italia (Scollo et al., 2009).

En cuanto a la velocidad de ascenso vertical de la pluma de cenizas, los valores se encuentran en el rango de 3 m/s a 27 m/s, siendo coherentes con otros cálculos realizados en el volcán Sabancaya por Simionato et al. (2022) y Wilkes

et al. (2022), así como con otras erupciones vulcanianas estudiadas en el mundo (6.7 m/s – 23.8 m/s) por Tournigand et al. (2017). Aunque el uso de algoritmos de flujo óptico permitiría un análisis más detallado de la turbulencia y las velocidades de la pluma, el método propuesto ofrece una estimación inicial de las velocidades de ascenso vertical de la pluma de cenizas. Además, esta metodología es fácil de implementar y no requiere equipos especializados, lo que la hace accesible para estudios de monitoreo volcánico de bajo costo. Sin embargo, es importante tener en cuenta que las velocidades de ascenso de la pluma pueden variar según las condiciones atmosféricas y las características específicas de cada erupción volcánica. Por lo tanto, se recomienda complementar estos resultados con mediciones adicionales y análisis más detallados en futuras investigaciones.

En cuanto a la dirección de dispersión de las plumas de ceniza, se pueden obtener a partir de las máscaras binarias generadas por el modelo implementado, logrando una tasa de éxito preliminar del 58%. Aunque este valor es calificable, las estrategias propuestas de expansión del conjunto de entrenamiento, suavizado de contornos y detección automática de múltiples plumas podrían mejorar significativamente el rendimiento y fortalecer el enfoque.

Con toda esta información, los científicos podrán tomar medidas preventivas y alertar a las comunidades cercanas en caso de un aumento significativo en la actividad del volcán Sabancaya. Además de monitorear la actividad del volcán Sabancaya, este sistema puede implementarse en otros volcanes activos en todo el mundo. Esto permitiría a los científicos comparar y analizar datos de diferentes ubicaciones, lo que podría llevar a una mejor comprensión de los patrones volcánicos y una mayor capacidad para predecir erupciones.

En última instancia, esta tecnología podría salvar vidas al brindar una alerta temprana a las comunidades vulnerables. Al implementar este sistema en otros volcanes activos, también se podrían establecer protocolos de evacuación más eficientes y precisos, lo que reduciría el riesgo de pérdidas humanas y materiales.

Además, esta tecnología permitiría a las autoridades y los organismos de protección civil tomar decisiones informadas y basadas en datos científicos, lo que aumentaría la efectividad de las medidas de prevención y mitigación de desastres.

En resumen, el uso de esta herramienta no solo es valioso para la gestión de riesgos volcánicos, sino que también tiene el potencial de revolucionar la forma en que se abordan los desastres naturales en general. Al proporcionar información en tiempo casi real sobre la actividad volcánica, este sistema podría ayudar a anticipar erupciones y tomar medidas preventivas con mayor precisión. Además, al permitir una mejor comprensión de los procesos volcánicos, se podrían desarrollar estrategias más efectivas de mitigación y respuesta a emergencias. En definitiva, esta tecnología tiene el potencial de salvar vidas y proteger comunidades en todo el mundo.

## CONCLUSIONES

- Se implementó un enfoque multiparamétrico que integra el análisis de señales sísmicas e imágenes visuales a través de técnicas efectivas de aprendizaje automático y aprendizaje profundo. Específicamente, se utilizó el algoritmo de clasificación supervisada CatBoost y se realizó un cuidadoso balanceo previo de los datos de entrada con SMOTE. Esto permitió discriminar automáticamente entre ocho tipos distintos de fenómenos sísmicos registrados en el Sabancaya, incluyendo eventos poco frecuentes, con una exactitud promedio sobresaliente del 94.5% en el conjunto independiente de prueba. Estos resultados confirman la madurez alcanzada por estas metodologías de inteligencia artificial ante grandes volúmenes de datos generados en crisis volcánicas. Además, se logró una segmentación precisa de las plumas eruptivas en imágenes, con tasas de detección superiores al 98%, lo cual avala la capacidad del sistema desarrollado para operar bajo condiciones ópticas adversas.
- Esta investigación demuestra la viabilidad de inferir cualitativamente la magnitud de las explosiones del Sabancaya utilizando aprendizaje automático y predictores sísmicos y meteorológicos. El modelo CatBoost categorizó adecuadamente entre eventos pequeños y grandes, con una precisión balanceada de 0.73. Si bien se requiere perfeccionamiento, la alta tasa de detección de explosiones intensas (93%) es alentadora para sistemas de alerta temprana. Estos resultados respaldan la novedosa metodología utilizada, que va más allá de la discriminación binaria lograda y sienta las bases para futuros desarrollos orientados a pronosticar cuantitativamente la altura de la columna eruptiva mediante el procesamiento en tiempo real de la información sísmica disponible.
- Gracias a la implementación de tecnologías como el procesamiento y análisis automatizado de imágenes, se ha logrado desarrollar un sistema de alerta temprana cuantitativa aplicado al volcán Sabancaya. Este sistema

logró caracterizar un 86% de las explosiones volcánicas estudiadas (1343), mediante la estimación de parámetros como la altura máxima de la columna (con una precisión de  $\pm 500$  m en comparación con las observaciones visuales) y velocidades de ascenso entre 3-27 m/s, consistentes con estudios previos. Esta capacidad para inferir automáticamente indicadores concretos sobre la peligrosidad de la actividad eruptiva optimiza sustancialmente la activación de protocolos de prevención y mitigación ante amenazas de origen volcánico.

- Los resultados de este estudio ponen de manifiesto el gran potencial de las técnicas de aprendizaje automático y visión artificial para mejorar los sistemas de monitoreo y alerta temprana ante actividad eruptiva volcánica. Específicamente, mediante enfoques novedosos basados en el procesamiento avanzado de señales sísmicas y flujos de video en tiempo real, fue posible detectar y caracterizar explosiones del volcán Sabancaya con un alto grado de precisión.

## BIBLIOGRAFÍA

- Álvarez, I., García, L., Cortes, G., Benítez, C., & De la Torre, Á. (2012). Discriminative feature selection for automatic classification of volcano-seismic signals. *IEEE Geoscience and Remote Sensing Letters: A Publication of the IEEE Geoscience and Remote Sensing Society*, 9(2), 151–155. <https://doi.org/10.1109/lgrs.2011.2162815>
- Bonadonna, C., & Phillips, J. C. (2003). Sedimentation from strong volcanic plumes. *J. Geophys. Res.*, 108(B7).
- Canário, J. P., Mello, R., Curilem, M., Huenupan, F., & Rios, R. (2020). In-depth comparison of deep artificial neural network architectures on seismic events classification. *J. Volcanol. Geotherm. Res.*, 401(106881), 106881.
- Carey, S., & Bursik, M. (2015). Volcanic Plumes. En H. Sigurdsson (Ed.), *The Encyclopedia of Volcanoes* (pp. 571-585). Elsevier.
- Centeno, R., & Rivera, M. (2020). Reconocimiento automático de señales sísmicas de origen volcánico para la alerta temprana de erupciones volcánicas del sur del Perú. <https://repositorio.igp.gob.pe/handle/20.500.12816/4783>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *J. Artif. Intell. Res.*, 16, 321-357.
- Coppola, D., Valade, S., Masias, P., Laiolo, M., Massimetti, F., Campus, A., Aguilar, R., Ancasi, R., Apaza, F., Ccallata, B., Cigolini, C., Cruz, L. F., Finizola, A., Gonzales, K., Macedo, O., Miranda, R., Ortega, M., Paxi, R., Taípe, E., & Valdivia, D. (2022). Shallow magma convection evidenced by excess degassing and thermal radiation during the dome-forming Sabancaya eruption (2012–2020). *Bulletin of Volcanology*, 84(2), 1–19. <https://doi.org/10.1007/s00445-022-01523-1>
- Del Carpio J. A., & Rivera, M. (2020). Evaluación geofísica del comportamiento dinámico actual del volcán Sabancaya, periodo 1 de diciembre de 2019-2 de febrero de 2020. <https://repositorio.igp.gob.pe/handle/20.500.12816/4753>
- Esmaili, S., Krishnan, S., & Raahemifar, K. (2004). Content based audio classification and retrieval using joint time-frequency analysis. *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, 5, V-665–668 vol.5.
- Falcin, A., Métaixian, J.-P., Mars, J., Stutzmann, É., Komorowski, J.-C., Moretti, R., Malfante, M., Beauducel, F., Saurel, J.-M., Dessert, C., Burtin, A., Ucciani, G., Chabalier, J.-B. de, & Lemarchand, A. (2021). A machine-learning

- approach for automatic classification of volcanic seismicity at La Soufrière Volcano, Guadeloupe. *J. Volcanol. Geotherm. Res.*, 411(107151), 107151.
- Folch, A., Costa, A., & Basart, S. (2012). Validation of the FALL3D ash dispersion model using observations of the 2010 Eyjafjallajökull volcanic ash clouds. *Atmospheric Environment (Oxford, England: 1994)*, 48, 165–183. <https://doi.org/10.1016/j.atmosenv.2011.06.072>
- Fries, A., Dominguez, L., Jarvis, P. A., Pistolesi, M., Manrique, N., Aguilar, R., Valdivia, D., Rossi, E., Pollastri, S., Horwell, C. J., & Bonadonna, C. (2023). The post-2016 long-lasting Vulcanian activity of Sabancaya volcano (Peru) and associated aeolian remobilisation of volcanic ash. *J. Volcanol. Geotherm. Res.*, 441(107876), 107876.
- Gerbe, M.-C., & Thouret, J.-C. (2004). Role of magma mixing in the petrogenesis of tephra erupted during the 1990–98 explosive activity of Nevado Sabancaya, southern Peru. *Bulletin of Volcanology*, 66(6), 541–561. <https://doi.org/10.1007/s00445-004-0340-3>
- Gösgens, M., Zhiyanov, A., Tikhonov, A., & Prokhorenkova, L. (2022). Good classification measures and how to find them. 17136-17147.
- Hasegawa, Y., Sugai, A., Hayashi, Y., Hayashi, Y., Saito, S., & Shimbori, T. (2015). Improvements of volcanic ash fall forecasts issued by the Japan Meteorological Agency. *Journal of Applied Volcanology*, 4(1), 2. <https://doi.org/10.1186/s13617-014-0018-2>
- Hassan AitLaasri, E., Akhouayri, E.-S., Driss, A. A., & Atmani. (2013). Seismic signal classification using multi-layer perceptron neural network. *Int. J. Comput. Appl.*, 79(15), 35-43.
- Havskov, J., & Alguacil, G. (2015). Instrumentation in earthquake seismology. *Instrumentation in Earthquake Seismology*, 1-413. <https://doi.org/10.1007/978-3-319-21314-9/COVER>
- Hibert, C., Provost, F., Jean-Philippe, A. M., Maggi, Stumpf, A., & Ferrazzini, V. (2017). Automatic identification of rockfalls and volcano-tectonic earthquakes at the Piton de la Fournaise volcano using a Random Forest algorithm. *J. Volcanol. Geotherm. Res.*, 340, 130-142.
- Huang, X., & Zhang, L. (2009). Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines. *International Journal of Remote Sensing*, 30(8), 1977-1987. <https://doi.org/10.1080/01431160802546837>

- Ibs-von Seht, M. (2008). Detection and identification of seismic signals recorded at Krakatau volcano (Indonesia) using artificial neural networks. *Journal of Volcanology and Geothermal Research*, 176(4), 448–456. <https://doi.org/10.1016/j.jvolgeores.2008.04.015>
- Iglovikov, V., Seferbekov, S., Buslaev, A., & Shvets, A. (2018). TernaNetV2: Fully Convolutional Network for Instance Segmentation. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 233–237.
- Jay, J. A., Delgado, F. J., Torres, J. L., Pritchard, M. E., Macedo, O., & Aguilar, V. (2015). Deformation and seismicity near Sabancaya volcano, southern Peru, from 2002 to 2015. *Geophysical Research Letters*, 42(8), 2780–2788. <https://doi.org/10.1002/2015gl063589>
- Jenkins, S. F., Wilson, T. M., Magill, C., Miller, V., Stewart, C., Blong, R., Marzocchi, W., Boulton, M., Bonadonna, C., & Costa, A. (2015). Volcanic ash fall hazard and risk. In *Global Volcanic Hazards and Risk* (pp. 173–222). Cambridge University Press.
- Juvigné, E., Thouret, J. C., Loutsch, I., Lamadon, S., Frechen, M., Fontugne, M., ... & Marino, J. (2008). Téphrostratigraphie et chronologie dans la region des Nevados Ampato et Sabancaya, sud du Pérou. *Quaternaire*, 19(2), 161–178.
- Kumagai, H., Mothes, P., Ruiz, M., & Maeda, Y. (2015). An approach to source characterization of tremor signals associated with eruptions and lahars. *Earth Planets Space*, 67(1).
- Lara, P. E. E., Fernandes, C. A. R., Inza, A., Mars, J. I., Metaxian, J.-P., Dalla Mura, M., & Malfante, M. (2020). Automatic multichannel volcano-seismic classification using machine learning and EMD. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1322–1331. <https://doi.org/10.1109/jstars.2020.2982714>.
- Machacca Puma, R., Del Carpio Calienes, J. A., Rivera Porras, M. A., Tavera Huarache, H. J., Macedo Franco, L. D., Concha Calle, J. A., Lazarte Zepa, I. A., Centeno Quico, R. G., Puma Sacsi, N. C., Torres Aguilar, J. L., Vargas Alva, K. A., Cruz Igme, J. E., Velarde Quispe, L., Vilca Nina, J., & Malpartida Garay, A. R. (2021). Monitoring of active volcanoes in Peru by the Instituto Geofísico del Perú. *Volcanica*, 4(S1), 49–71. <https://doi.org/10.30909/vol.04.s1.4971>
- Machacca, R., Lesage, P., Tavera, H., Pesicek, J. D., Caudron, C., Torres, J. L., Puma, N., Vargas, K., Lazarte, I., Rivera, M., & Burgisser, A. (2023). The 2013–2020 seismic activity at Sabancaya Volcano (Peru): Long lasting unrest and eruption. *Journal of Volcanology and Geothermal*

- Research, 435(107767), 107767.  
<https://doi.org/10.1016/j.jvolgeores.2023.107767>
- MacQueen, P., Delgado, F., Reath, K., Pritchard, M. E., Bagnardi, M., Milillo, P., Lundgren, P., Macedo, O., Aguilar, V., Ortega, M., Ancasí, R., Lazarte Zepa, I. A., & Miranda, R. (2020). Volcano-Tectonic Interactions at Sabancaya Volcano, Peru: Eruptions, Magmatic Inflation, Moderate Earthquakes, and Fault Creep. *Journal of Geophysical Research: Solid Earth*, 125(5). <https://doi.org/10.1029/2019JB019281>
- Malfante, M., Dalla Mura, M., Mars, J. I., Métaxian, J.-P., Macedo, O., & Inza, A. (2018a). Automatic classification of volcano seismic signatures. *Journal of Geophysical Research. Solid Earth*, 123(12), 10,645-10,658. <https://doi.org/10.1029/2018jb015470>
- Malfante, M., Dalla Mura, M., Metaxian, J.-P., Mars, J. I., Macedo, O., & Inza, A. (2018b). Machine learning for volcano-seismic signals: Challenges and perspectives. *IEEE Signal Processing Magazine*, 35(2), 20–30. <https://doi.org/10.1109/msp.2017.2779166>.
- Manrique, N., Lazarte, I., Cueva, K., Rivera, M., & Aguilar, R. (2018). Actividad del volcán Sabancaya (Perú) 2016-2017: Características de las emisiones de ceniza y análisis granulométrico. *Foro Internacional Los Volcanes y su Impacto*, 8, 76-80.
- Mastin, L. G., Guffanti, M., Servranckx, R., Webley, P., Barsotti, S., Dean, K., Durant, A., Ewert, J. W., Neri, A., Rose, W. I., Schneider, D., Siebert, L., Stunder, B., Swanson, G., Tupper, A., Volentik, A., & Waythomas, C. F. (2009). A multidisciplinary effort to assign realistic source parameters to models of volcanic ash-cloud transport and dispersion during eruptions. *Journal of Volcanology and Geothermal Research*, 186(1–2), 10–21. <https://doi.org/10.1016/j.jvolgeores.2009.01.008>
- Marzano, F. S., Mereu, L., Montopoli, M., Cimini, D., & Martucci, G. (2015). Volcanic Ash Cloud Observation using Ground-based Ka-band Radar and Near-Infrared Lidar Ceilometer during the Eyjafjallajökull eruption. *Annals of Geophysics*, 57. <https://doi.org/10.4401/ag-6634>
- Mori, A., & Kumagai, H. (2019). Estimating plume heights of explosive eruptions using high-frequency seismic amplitudes. *Geophysical Journal International*, 219(2), 1365-1376. <https://doi.org/10.1093/gji/ggz374>
- McKee, K. F., Roman, D. C., Waite, G. P., & Fee, D. (2022). Silent very long period seismic events (VLPs) at Stromboli volcano, Italy. *Geophysical Research Letters*, 49(23). <https://doi.org/10.1029/2022gl100735>

- McNutt, S. R. (1994). Volcanic tremor amplitude correlated with eruption explosivity and its potential use in determining ash hazards to aviation. *U.S. Geological Survey Bulletin*, 2047, 377.
- Mitchell, M. (2019). Artificial intelligence hits the barrier of meaning. *Information (Basel)*, 10(2), 51. <https://doi.org/10.3390/info10020051>
- National Centers for Environmental Prediction/National Weather Service/NOAA/U.S. Department of Commerce. (2015). *NCEP GDAS/FNL 0.25 Degree Global Tropospheric Analyses and Forecast Grids [Data set]*. UCAR/NCAR - Research Data Archive.
- Orozco-Alzate, M., Londoño-Bonilla, J. M., Nale, V., & Bicego, M. (2019). Towards better volcanic risk-assessment systems by applying ensemble classification methods to triaxial seismic-volcanic signals. *Ecol. Inform.*, 51, 177-184.
- Peixoto, A. A. T., Fernandes, C. A. R., Lara, P. E. E., Inza, A., Mars, J. I., Métaixian, J. P., ... & Malfante, M. (2021). Tensor-based learning framework for automatic multichannel volcano-seismic classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4517-4529.
- Prejean, S. G., & Brodsky, E. E. (2011). Volcanic plume height measured by seismic waves based on a mechanical model. *J. Geophys. Res.*, 116(B1).
- Poli, P., & Shapiro, N. M. (2022). Rapid characterization of large volcanic eruptions: Measuring the impulse of the Hunga Tonga Ha'apai explosion from teleseismic waves. *Geophys. Res. Lett.*, 49(8).
- Puma, N., Centeno, R., Vargas, K., Lazarte, I., Torres, J., Rivera, M., & Del Carpio, J. (2021). *Evaluación de la actividad eruptiva del volcán Sabancaya a partir de datos geofísicos y observaciones de campo (abril –noviembre, 2021)*. <http://repositorio.igp.gob.pe/handle/20.500.12816/5077>
- Rahman, M. A., & Wang, Y. (2016). Optimizing intersection-over-union in deep neural networks for image segmentation. In *Advances in Visual Computing* (pp. 234–244). Springer International Publishing.
- Rajaeitabrizi, Y., Salehiozoumchelouei, R., D'Auria, L., & Sánchez de la Rosa, J. L. (2020). Multistage adaptive spectral subtraction of seismic signals. <https://doi.org/10.5194/egusphere-egu2020-4853>
- Rey-Devesa, P., Benítez, C., Prudencio, J., Gutiérrez, L., Cortés-Moreno, G., Titos, M., Koulakov, I., Zuccarello, L., & Ibáñez, J. M. (2023). Volcanic early warning using Shannon entropy: Multiple cases of study. *Journal of*

- Geophysical Research. Solid Earth, 128(6).  
<https://doi.org/10.1029/2023jb026684>
- Russell, S. J., & Norvig, P. (2004). *Inteligencia Artificial: un enfoque moderno* (No. 04; Q335, R8y 2004.).
- Samaniego, P., Rivera, M., Mariño, J., Guillou, H., Liorzou, C., Zerathe, S., Delgado, R., Valderrama, P., & Scao, V. (2016). The eruptive chronology of the Ampato–Sabancaya volcanic complex (Southern Peru). *Journal of Volcanology and Geothermal Research*, 323, 110–128.  
<https://doi.org/10.1016/j.jvolgeores.2016.04.038>
- Sciotto, M., Cannata, A., Prestifilippo, M., Scollo, S., Fee, D., & Privitera, E. (2019). Unravelling the links between seismo-acoustic signals and eruptive parameters: Etna lava fountain case study. *Scientific Reports*, 9(1), 16417.  
<https://doi.org/10.1038/s41598-019-52576-w>
- Scollo, S., Prestifilippo, M., Spata, G., D'Agostino, M., & Coltelli, M. (2009). Monitoring and forecasting Etna volcanic plumes. *Natural Hazards and Earth System Sciences*, 9(5), 1573–1585. <https://doi.org/10.5194/nhess-9-1573-2009>
- Scollo, Simona, Boselli, A., Coltelli, M., Leto, G., Pisani, G., Spinelli, N., & Wang, X. (2012). Monitoring Etna volcanic plumes using a scanning LiDAR. *Bulletin of Volcanology*, 74(10), 2383–2395.  
<https://doi.org/10.1007/s00445-012-0669-y>
- Simionato, R., Jarvis, P. A., Rossi, E., & Bonadonna, C. (2022). PlumeTraP: A new MATLAB-based algorithm to detect and parametrize volcanic plumes from visible-wavelength images. *Remote Sens. (Basel)*, 14(7), 1766.
- Talagrand, O. (1997). Assimilation of Observations, an Introduction (gtSpecial IssueltData Assimilation in Meteorology and Oceanography: Theory and Practice). *Journal of the Meteorological Society of Japan. Ser. II*, 75(1B), 191–209. [https://doi.org/10.2151/JMSJ1965.75.1B\\_191](https://doi.org/10.2151/JMSJ1965.75.1B_191)
- Titos, M., Bueno, A., Garcia, L., Benitez, M. C., & Ibanez, J. (2019). Detection and classification of continuous volcano-seismic signals with recurrent neural networks. *IEEE Trans. Geosci. Remote Sens.*, 57(4), 1936–1948.
- Tournigand, P.-Y., Taddeucci, J., Gaudin, D., Peña Fernández, J. J., Del Bello, E., Scarlato, P., Kueppers, U., Sesterhenn, J., & Yokoo, A. (2017). The initial development of transient volcanic plumes as a function of source conditions. *Journal of Geophysical Research. Solid Earth*, 122(12), 9784–9803. <https://doi.org/10.1002/2017jb014907>

- Travada y Córdova, V. (1958). El suelo de Arequipa convertido en cielo. Lima, Editorial Lumen.
- Trnkoczy, A. (2009). *Understanding and parameter setting of STA/LTA trigger algorithm*. Deutsches GeoForschungsZentrum GFZ. [https://doi.org/10.2312/GFZ.NMSOP\\_R1\\_IS\\_8.1](https://doi.org/10.2312/GFZ.NMSOP_R1_IS_8.1)
- Tucker, S., & Brown, G. J. (2005). Classification of transient sonar sounds using perceptually motivated features. *IEEE Journal of Oceanic Engineering*, 30(3), 588–600. <https://doi.org/10.1109/joe.2005.850910>
- Vassallo, M., Satriano, C., & Lomax, A. (2012). Automatic picker developments and optimization: A strategy for improving the performances of automatic phase pickers. *Seismological Research Letters*, 83(3), 541–554. <https://doi.org/10.1785/gssrl.83.3.541>
- Wilkes, T. C., Pering, T. D., & McGonigle, A. J. S. (2022). Semantic segmentation of explosive volcanic plumes through deep learning. *Computers & Geosciences*, 168(105216), 105216. <https://doi.org/10.1016/j.cageo.2022.105216>
- Wilson, G., Wilson, T. M., Deligne, N. I., & Cole, J. W. (2014). Volcanic hazard impacts to critical infrastructure: A review. *Journal of Volcanology and Geothermal Research*, 286, 148–182. <https://doi.org/10.1016/J.JVOLGEORES.2014.08.030>
- Wilson, T. M., Jenkins, S., & Stewart, C. (2015). Impacts from Volcanic Ash Fall. In *Volcanic Hazards, Risks and Disasters* (pp. 47–86). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-396453-3.00003-4>.

## **Apéndice 1**

### **Tabla general de parámetros de las características**

Para identificar y comprender las señales sísmicas de manera efectiva, es crucial determinar un conjunto de características significativas que estén relacionadas con las mediciones realizadas en las observaciones. Normalmente, estas representaciones se obtienen mediante la extracción de parámetros y características de los datos, los cuales se utilizan en un nuevo marco de referencia para clasificar eventos sísmicos individuales. En este estudio, se extrajeron características tanto de la forma de onda (como descriptores estadísticos y de forma) como del espectro, teniendo en cuenta sus diferentes características. Finalmente, se seleccionó un subconjunto de 27 características (ver Tabla A1).

Tabla A1. Conjunto de características utilizadas para representar cada señal transitoria.

|                                                                | Ecuación                                                                                       | Ref.    |
|----------------------------------------------------------------|------------------------------------------------------------------------------------------------|---------|
| <b>Características fenomenológicas:</b>                        |                                                                                                |         |
| Duración (dr)                                                  | $N = length(S)$                                                                                | 1       |
| Energía(en)                                                    | $E = \sum_{i=1}^n S[i]^2; E_i = S[i]^2$                                                        | 2       |
| Índice de frecuencia (fi)                                      | $FI = \log_{10} \left( \frac{E_{\text{high frequencies}}}{E_{\text{low frequencies}}} \right)$ | 3       |
| Radio de Ataque (roa)                                          | $\max_i \left( \frac{S[i] - S[i-1]}{n} \right)$                                                | 4       |
| Radio de Decaimiento (rod)                                     | $\min_i \left( \frac{S[i] - S[i+1]}{n} \right)$                                                | 5       |
| <b>Características estadísticas:</b>                           |                                                                                                |         |
| Media (us)                                                     | $\mu_s = \frac{1}{n} \sum_i S[i]$                                                              | 6       |
| Desviación estándar (ds)                                       | $\sigma_s = \sqrt{\frac{1}{(n-1)} \sum_i (S[i] - \mu_s)^2}$                                    | 7       |
| Asimetría (A)                                                  | $\frac{1}{n} \sum_i \left( \frac{S[i] - \mu_s}{\sigma_s} \right)^3$                            | 8       |
| Curtosis (k)                                                   | $\frac{1}{n} \sum_i \left( \frac{S[i] - \mu_s}{\sigma_s} \right)^4$                            | 9       |
| Posición de energía central i (ci)                             | $\bar{i} = \frac{1}{E} \sum_{E_i} \cdot i$                                                     | 10      |
| Ancho de banda del valor de RMS (rmsb)                         | $B_i = \sqrt{\frac{1}{E} \sum_i i^2 \cdot E_i - \bar{i}^2}$                                    | 11      |
| Asimetría media (msk)                                          | $\sqrt{\frac{\sum_i (i - \bar{i})^3 E_i}{E \cdot B_i^3}}$                                      | 12      |
| Curtosis media (mk)                                            | $\sqrt{\frac{\sum_i (i - \bar{i})^4 E_i}{E \cdot B_i^4}}$                                      | 13      |
| Entropía (et)                                                  | $\sum_i P_f(TFD(n, f)) \log_2(P_f(TFD(n, f)))$                                                 | 14      |
| Brillo (br)                                                    | $\frac{\sum_i f \cdot TFD(n, f)}{\sum_i TFD(n, f)}$                                            | 15      |
| Entropía de Shannon (sh)                                       | $-\sum_i P(S_i) \log_2(P(S_i))$                                                                | 16      |
| Entropía de Rényi(rh)                                          | $\frac{1}{1-a} \log_2 \left( \sum_i P(S_i)^a \right)$                                          | 17      |
| <b>Parámetros de transformación en el dominio de la señal:</b> |                                                                                                |         |
| LPC (lpc1, lpc2, lpc3, lpc4, lpc5)                             | $S[n] = \left( \sum_i a_k \cdot S[n-k] \right) + \text{err}[n]$                                | 18 - 22 |
| Coeficientes Cepstrales (cc1, cc2, cc3, cc4, cc5)              | $\text{Re} \left( FFT^{-1} \left( \log \left( \text{abs}(FFT(S_i)) \right) \right) \right)$    | 23 - 27 |

Nota: Los símbolos utilizados en esta tabla se explican en Esmaili et al. (2004), Álvarez et al., (2011), y Malfante et al. (2018a, b). RMS, raíz cuadrática media; LPC, Coeficientes Predictivos Lineales.

## Apéndice 2

### Calibración de imágenes visibles del volcán Sabancaya

La calibración de imágenes visibles capturadas por cámaras de vigilancia volcánica es un paso esencial para transformar las coordenadas en píxeles de las imágenes a un sistema métrico real, lo cual permite medir parámetros cuantitativos, como la altura de una columna eruptiva.

En el caso del volcán Sabancaya, utilizamos imágenes visibles calibradas de una cámara ubicada en el flanco noreste, en la localidad de Chivay, llamada SBYA. Esta cámara, una Campbell Scientific CC5MPX, cuenta con un sensor de imagen CMOS progresivo de 1/2.5" y una resolución máxima de  $2592 \times 1944$  (JPEG). Su distancia focal es de 4-12 mm, con una apertura de F1.6 y un campo de visión horizontal angular de  $80^\circ$ , con un teleobjetivo de  $27^\circ$ . La calibración de la cámara CC5MPX se realizó siguiendo el procedimiento descrito en (Simionato et al., 2022).

Para estimar la altura de la pluma, nuestro algoritmo utiliza la posición y orientación de la cámara, obtenidas mediante el sistema de posicionamiento global y una herramienta 3D de simulación de la cámara, alineada con el modelo digital de elevación (DEM) del volcán. Consideramos que la pluma volcánica tiene una profundidad despreciable y está localmente confinada a un plano vertical que varía según la dirección del viento a diferentes alturas. La incertidumbre en la altura de la columna fue de  $\pm 500$  m, equivalente a la distancia entre las líneas horizontales trazadas en las imágenes visibles calibradas. La altura de la columna a lo largo del tiempo fue evaluada manualmente por un operador.

La posición vertical ( $Z_i$ ) de un solo píxel dentro de la imagen, medida con respecto a la altitud de la cámara, se relaciona con la distancia horizontal ( $Y$ ) de la cámara desde el plano de la imagen que contiene la pluma, y con los

parámetros geométricos de la cámara, mediante una fórmula específica. De esta manera, podemos estimar la altura de la columna eruptiva.

$$\Delta z_j = Y \left( \tan \left( \phi - \frac{\beta_v}{2} + j \frac{\beta_v}{N_v} \right) - \tan \left( \phi - \frac{\beta_v}{2} + (j-1) \frac{\beta_v}{N_v} \right) \right),$$

$$z_j^{err} = \frac{Y}{2} \left( \tan \left( \phi - \frac{\beta_v}{2} + j \frac{\beta_v}{N_v} \right) - \tan \left( \phi - \frac{\beta_v}{2} + (j-1) \frac{\beta_v}{N_v} \right) \right).$$

Donde  $\phi$  es la inclinación de la cámara con respecto a la horizontal,  $\beta_v$  el campo de visión vertical (FOV),  $j$  la posición vertical (medida en píxeles desde el fondo de la imagen) del píxel cuya altura se está midiendo y  $N_v$  el número de píxeles en la dirección vertical. Así,  $\beta_v/N_v$  es el ángulo vertical subtendido por un solo píxel (Simionato et al., 2022).

La Fig. A1 muestra un diagrama esquemático de la calibración geométrica de la cámara desde una vista lateral. Las líneas rojas representan los límites verticales del encuadre de la imagen capturada por la cámara. La línea azul se dirige hacia el centro de la imagen. La región sombreada en gris simboliza la extensión espacial que abarca un solo píxel individual de la imagen (mostrado de manera exagerada con fines ilustrativos). Y es la distancia medida entre el plano de la cámara e imagen. El ángulo  $\phi$  representa la inclinación de la orientación de la cámara con respecto a la horizontal. El ángulo  $\beta_v$ , corresponde al campo de visión vertical (FOV) de la lente. La variable  $j$  indica la posición vertical de un píxel arbitrario seleccionado sobre la imagen digital resultante. Finalmente,  $N_v$  es el número total de píxeles en la dimensión vertical de la imagen. Las alturas  $z_1$  y  $z_2$  denotan la elevación mínima y máxima sobre el terreno que son visualizadas a través del píxel seleccionado de coordenadas  $j$ . Este diagrama ha sido adaptado a partir de Simionato et al. (2022).




Figura A1: Esquemática de la calibración geométrica (vista lateral). Las líneas rojas representan los límites de la imagen, la azul es la línea al centro de la imagen y la región sombreada en gris representa la extensión de un solo píxel (exagerada). Y es la distancia cámara-plano de la imagen,  $\phi$  la inclinación de la cámara,  $\beta_v$  el campo de visión vertical (FOV),  $j$  la posición vertical del píxel seleccionado en la imagen y  $N_v$  el número de píxeles en la dirección vertical. Las alturas  $z_1$  y  $z_2$  representan la altura mínima y máxima del píxel  $j$ . (modificado de Simionato et al. 2022).

Para la cámara Campbell de la estación SBYA, se conoce un Y máximo de 32.14 km y un Y mínimo de 31.6 km. Además, de un FOV vertical de  $0.01^\circ$  y un FOV horizontal de  $0.02^\circ$  y un ángulo de inclinación de cámara de  $5^\circ$ .

$$\Delta z_j = 31848 \left( \tan \left( 5 - \frac{0.01}{2} + (5) \frac{0.01}{1280} \right) - \tan \left( 5 - \frac{0.01}{2} + (4) \frac{0.01}{1280} \right) \right)$$

$$z_i = 3.19876 \text{ m}$$

$$z_j^{err} = \frac{31848}{2} \left( \tan \left( 5 - \frac{0.01}{2} + (5) \frac{0.01}{1280} \right) - \tan \left( 5 - \frac{0.01}{2} + (4) \frac{0.01}{1280} \right) \right)$$

$$z_j^{err} = 1.59938 \text{ m}$$

Por lo tanto, se aplica este valor  $Z_j$  de 3.2 m a cada píxel para obtener las coordenadas físicas de cada píxel y el error asociado  $z_j^{err} = 1.6 \text{ m}$ .

