



Optimización de la vigilancia volcánica: visión computacional para la detección de emisiones de ceniza del volcán Popocatepetl

Eric B. Tellez Ugalde

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0009-0002-5654-7518

Miguel Ángel Vela Rosas

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0000-0003-3621-1769

Yadir Emmanuel Sánchez Tafolla

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0009-0006-8054-4391

Angélica Fernández Pineda

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0009-0000-1616-1464

Fátima Teresa García Fierros

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0009-0007-8236-9651

Humberto Jesús Abaffy Castillo

Universidad de Bergen, Bergen, Noruega.
ORCID: 0009-0005-5237-974X

Hugo Delgado Granados

Universidad Nacional Autónoma de México, Instituto de Geofísica, Ciudad de México, México.
ORCID: 0000-0001-5263-7968

Recepción: 12 de noviembre de 2024.

Aceptación: 21 de agosto de 2025.

Septiembre 2025 • número de revista 13 • DOI: 10.22201/ dgtic.26832968e.2025.13.55

Optimización de la vigilancia volcánica: visión computacional para la detección de emisiones de ceniza del volcán Popocatepetl

Resumen

El monitoreo del volcán Popocatepetl busca proporcionar herramientas a las autoridades de protección civil para mitigar los riesgos asociados con la actividad volcánica. En México, el Cenapred y la UNAM llevan a cabo esta vigilancia para reducir los riesgos asociados a las emisiones de ceniza, los cuales pueden afectar la salud de la población y causar interrupciones en los servicios de aeronavegación. El monitoreo visual se realiza mediante cámaras web que transmiten al Cenapred, donde se requiere la presencia de personal las 24 horas del día, por lo que un sistema automatizado sería crucial para optimizar los recursos humanos disponibles. Para abordar esta necesidad, se propone un modelo de visión computacional que reconozca las emisiones de ceniza. Los datos para el entrenamiento del modelo se obtuvieron gracias a la red de cámaras operadas por Cenapred y Webcams de México, y la programación del mismo se realizó con TensorFlow en equipos Atlas de Huawei. Se obtuvo una precisión de 98% en el modelo de clasificación de imágenes en dos categorías: con actividad y sin actividad; y 84% con tres categorías: sin actividad, gases y cenizas.

Palabras Clave: inteligencia artificial, visión computacional, clasificación de imágenes, detección de objetos, monitoreo volcánico, emisión de ceniza, Popocatepetl.

Optimizing volcanic monitoring: computer vision for detecting ash emissions from Popocatepetl volcano

Abstract

Monitoring the Popocatepetl volcano aims to provide civil protection authorities with tools to mitigate the risks associated with volcanic activity. In Mexico, the National Center for Disaster Prevention (Cenapred) and the National Autonomous University of Mexico (UNAM) conduct surveillance of the volcano to reduce the risks associated with ash emissions, which can affect public health and disrupt air navigation services. Visual monitoring is carried out using webcams transmitting to Cenapred, where personnel is needed 24/7, making an automated system crucial to optimize available human resources. To address this need, a computer vision model is proposed to recognize ash emissions. The dataset for training the model was obtained from the cameras operated by Cenapred and Webcams de Mexico, and the coding was made with TensorFlow on a Huawei's Atlas server. A precision of 98% was obtained in an image classification model with two categories: activity and no activity; and 84% in three categories: no activity, gas and ashes.

Keywords: artificial intelligence, computer vision, image classification, object detection, volcanic monitoring, ash emission, Popocatepetl.

Introducción

El volcán Popocatepetl es uno de los volcanes más monitoreados del mundo debido al riesgo constante que representa para más de 25 millones de personas que habitan en un radio de 100 km alrededor de su cráter, incluyendo una extensa área urbana donde convergen poblaciones de los estados de Puebla, Morelos, Tlaxcala y la Ciudad de México [1]. Los peligros asociados a la segunda montaña más alta de México incluyen flujos piroclásticos, avalanchas y colapsos del edificio volcánico, así como la emisión de nubes de ceniza capaces de cubrir amplias zonas del centro del país [2]; fenómenos que, en suma, tienen el potencial de causar graves efectos como pérdida de vidas humanas, destrucción de infraestructuras, daños a la agricultura y la ganadería, así como desplazamiento de población.

La única manera de percibir y evaluar la actividad de un volcán es mediante una vigilancia sistemática, usando diversos métodos visuales e instrumentales. Si se aplican en las fases previas a una erupción, se pueden detectar cambios cualitativos y cuantitativos en la actividad, lo que podría permitir predecir una erupción inminente a corto plazo. Por lo tanto, es crucial implementar sistemas de vigilancia y monitoreo en todos los volcanes potencialmente peligrosos para establecer programas preventivos ante posibles desastres [3]. En conjunto con el monitoreo del volcán, la comunicación oportuna a la sociedad es esencial para mitigar riesgos; ambas permiten alertar a la población y facilitar la implementación de medidas de prevención y respuesta ante posibles amenazas volcánicas [4].

Estudios han demostrado que la exposición a ceniza volcánica puede provocar afecciones respiratorias y oculares [5]. Las erupciones volcánicas explosivas tienden a liberar grandes cantidades de ceniza y gases corrosivos, que ascienden hasta la troposfera superior y la estratosfera baja, zonas que coinciden con las altitudes utilizadas por las aeronaves comerciales. En las últimas décadas, más de 60 aviones han sufrido daños debido a nubes errantes de ceniza volcánica que han afectado tanto las rutas aéreas como las infraestructuras aeroportuarias [3]. Las emisiones de ceniza suponen un riesgo considerable para la navegación aérea, principalmente debido a los daños que estas partículas pueden causar en las turbinas de los aviones. Un caso emblemático es el incidente del vuelo 9 de British Airways en 1982, en el que la aeronave perdió potencia en sus cuatro motores tras atravesar una nube de ceniza del monte Galunggung en Indonesia. La tripulación logró recuperar el control de la aeronave después de descender varios miles de pies [6].

En la actualidad, muchos observatorios volcánicos emiten alertas dirigidas al tráfico aéreo. Una de las herramientas más empleadas en el monitoreo es la observación visual mediante cámaras en tiempo real, complementada por otros métodos como el monitoreo sísmico, geoquímico y geodésico. A través de estas cámaras, un equipo de analistas vigila la actividad volcánica para emitir avisos a las autoridades de protección civil y aeronáutica. Sin embargo, este enfoque requiere la presencia de personal especializado las 24 horas del día, los 365 días del año, lo que representa un desafío logístico y financiero significativo, especialmente en regiones con varios volcanes activos que demandan atención simultánea y en las que los observatorios cuentan con recursos humanos limitados. La dependencia en el monitoreo visual y manual no siempre es viable, lo que resalta la necesidad de

implementar herramientas automatizadas que complementen o incluso reemplacen algunas de estas tareas.

Aplicación de la inteligencia artificial al monitoreo volcánico

En los últimos años, las tecnologías de visión computacional han avanzado significativamente y se han extendido a diversas áreas del conocimiento, desde la medicina y la detección de huesos mediante las imágenes de rayos X [7] hasta la clasificación de especies nativas de frijol [8]. Su aplicación en el monitoreo volcánico puede resultar en soluciones de software valiosas para observatorios con alta actividad eruptiva simultánea, lo cual es útil en todo el mundo. Uno de los primeros ejemplos de monitoreo de volcanes con visión computacional se encuentra en el artículo de Bertuccio *et al.* [9] de 1999, una publicación en la que se hace uso de una arquitectura de red neuronal celular (CNN) para procesar imágenes del volcán Etna y del Stromboli en tiempo real. Ahí, se expone una nueva metodología (para aquel momento) con la que se pueden extraer parámetros físicos de los eventos, aunque este sistema se limita a actividad no paroxísmica.

Existen casos de éxito recientes del uso de este método en el área de monitoreo volcánico visual alrededor del mundo, por ejemplo [10], [11], [12], [13] y [14].

El presente artículo tiene como objetivo explicar el desarrollo de un sistema automatizado de detección de emisiones de ceniza en el volcán Popocatepetl bajo diversas condiciones atmosféricas y de actividad volcánica. Este sistema representa una innovación en el monitoreo del Popocatepetl; sin embargo, se limita a la actividad suficientemente visible por las cámaras, por lo que está diseñado como una herramienta complementaria para instituciones de protección civil, como el Cenapred, y de seguridad aérea, como los Servicios a la Navegación en el Espacio Aéreo Mexicano (SENEAM) mediante su Centro de Análisis y Pronósticos (CAPMA).

Datos

Los datos (imágenes) para alimentar los modelos son generados por las cámaras web de la red de monitoreo del Cenapred, disponibles para el público general en las plataformas de Webcams de México [15] y del propio Cenapred [16]. Estas imágenes fueron recopiladas, en su mayoría, a través de Observación Volcánica [17], un proyecto que, desde 2020, se dedica a generar boletines en redes sociales en donde se resume la actividad diaria del volcán. De forma adicional, se hicieron solicitudes de imágenes al Cenapred para incluir eventos que no se recopilaron en Observación Volcánica.

Las imágenes provienen principalmente de las cámaras de Tlamacas, Altzomoni, Tianguismanalco y San Nicolás de los Ranchos, las cuales se encuentran aproximadamente a 5, 11, 19 y 15 km del cráter, respectivamente [16]. Todas las cámaras son de alta definición y cuentan además con visión nocturna. También se utilizaron imágenes de cámaras antiguas las cuales fueron obtenidas de los reportes diarios que Cenapred publica desde los años 90. Algunas de las cámaras que se incluyeron fueron Canario, Juncos, Chipiquixtle y las cámaras antiguas de Tlamacas y Altzomoni. Asimismo, se incluyeron cámaras propias de Webcams de México, las cuales son Puebla y Amecameca.

El primer set de datos consistió de aproximadamente 2500 imágenes fijas. Se incluyeron imágenes de diferentes fases de actividad volcánica, que van desde la calma total hasta emisiones fumarólicas y explosiones con emisiones de ceniza con diferentes rangos intensidad. Para clasificar estas imágenes, se crearon diferentes categorías acordes al tipo de actividad del volcán. En un primer momento, se propusieron 18 categorías de acuerdo a todos los tipos de actividad volcánica combinada con las condiciones meteorológicas y hora del día de las observaciones, pero rápidamente fue obvio que esto sería innecesario y demasiado complicado. Debido a que el principal interés del monitoreo visual está en la ceniza, se decidió enfocar el modelo en ese fenómeno, por lo que una clasificación menos ambiciosa se propuso de la siguiente forma:

- Sin actividad: Volcán en calma.
- Emisiones de gas: Emisiones de gases volcánicos, principalmente vapor de agua, sin presencia significativa de ceniza.
- Emisiones de ceniza y gas: Aquellas emisiones con contenido de ceniza. Todas las emisiones de ceniza están acompañadas de gases volcánicos.

Las tres categorías abarcan imágenes tomadas tanto en condiciones de buena visibilidad como en condiciones de visibilidad limitada. Esta clasificación en tres fue una meta a mediano plazo del proyecto, puesto que se decidió realizar primero un código piloto de solo dos categorías, volcán con actividad y volcán sin actividad. Este código más simple también permitiría ver si habría la necesidad de recopilar imágenes diferentes, que, por sus características especiales, permitieran mejorar el modelo en caso necesario.

Clasificación de imágenes

La clasificación de imágenes es una técnica de visión computacional en la cual se le aplica una etiqueta alfabética (palabra o palabras) a una imagen. Es decir, el dato de entrada es una imagen y el de salida es una cadena de texto [18]. Con las imágenes clasificadas, se comenzó la escritura de un programa piloto con clasificación de imágenes en Jupyter Notebook [19] que nos diera información exploratoria acerca del comportamiento general del aprendizaje con este set de datos en particular. Para realizar esta tarea, se empleó la técnica de transferencia de aprendizaje que consiste en tomar una red neuronal ya entrenada y usarla para resolver un problema similar [20]; en este caso se usó MobileNetv2 [21]. El código base, a partir del cual se trabajó, se tomó de [22]. Al principio, se obtuvo un sobreajuste, es decir, las imágenes no eran suficientemente variadas y el modelo era incapaz de hacer predicciones o conclusiones precisas a partir de ningún otro dato que fuera de los de entrenamiento [23]. Para corregir esto, se aumentó la base de datos con más imágenes reales pero también se multiplicó ésta de manera artificial con la técnica de aumento de datos [24]. Este código escrito en Jupyter Notebook se ejecutó en Google Colab; sin embargo, pronto se cambió a un formato no interactivo de Python para poder hacer la ejecución directamente en el servidor Atlas de Huawei [25].

Con el modelo de clasificación de imágenes en dos categorías suficientemente comprendido, se procedió a ampliarlo a tres categorías, lo cual redujo significativamente su precisión. Para mejorarla, se aumentó nuevamente de manera artificial el conjunto de datos y se probaron ajustes en los optimizadores y en otros dos parámetros. Sin embargo, estos cambios no ofrecieron los resultados esperados, por lo que se optó por modificar el código en TensorFlow mediante la actualización de la instrucción de importación de imágenes a una versión mejorada y de ejecución más rápida [26].

A la par que se trataba de mejorar la precisión del programa para tres categorías, se intentó poner el modelo de clasificación de imágenes de dos categorías en un servidor de inferencia para la clasificación de imágenes y de video en tiempo real. A este paso del proyecto se le conoce como despliegue. En la Figura 1, se puede observar el flujo de trabajo completo, desde la obtención de las imágenes, pasando por la clasificación, la programación y el entrenamiento. En este proyecto, se pudo llegar hasta la obtención del modelo y, actualmente, se trabaja para realizar el despliegue.

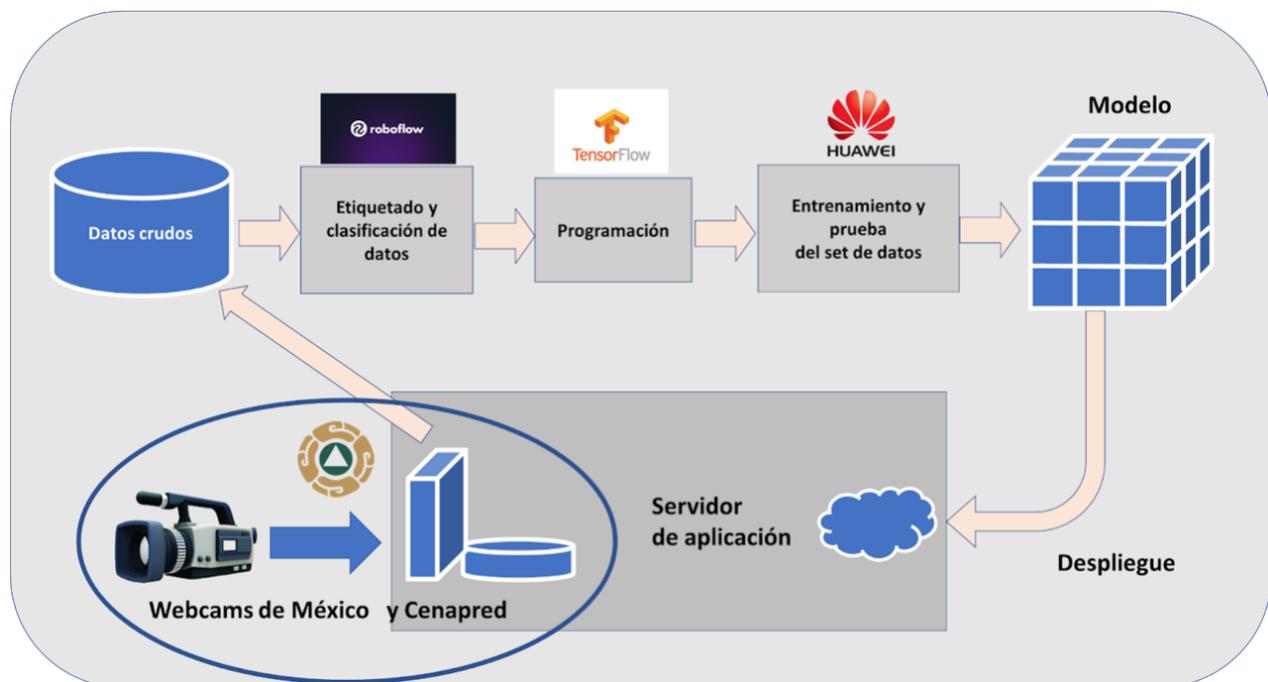


Fig. 1. Flujo de trabajo de este proyecto, desde la obtención de las imágenes hasta el despliegue en tiempo real.

Detección de objetos

Mientras se avanzaba en el despliegue del modelo de clasificación de imágenes en tiempo real, a la par, se utilizó el mismo set de imágenes para entrenar un modelo de detección de objetos. La detección de objetos es una técnica de visión computacional que tiene como

objetivo localizar objetos en imágenes digitales [27]. Para poder usar este modelo, primero es necesario etiquetar las imágenes de tal forma que, en cada imagen, se resalte el objeto u objetos de interés. En la Figura 2, podemos ver una imagen etiquetada. En color verde, tenemos la nube de ceniza volcánica, en color morado está el volcán y en color azul están las nubes meteorológicas. El etiquetado de 1523 imágenes se realizó en la página de Roboflow [28].

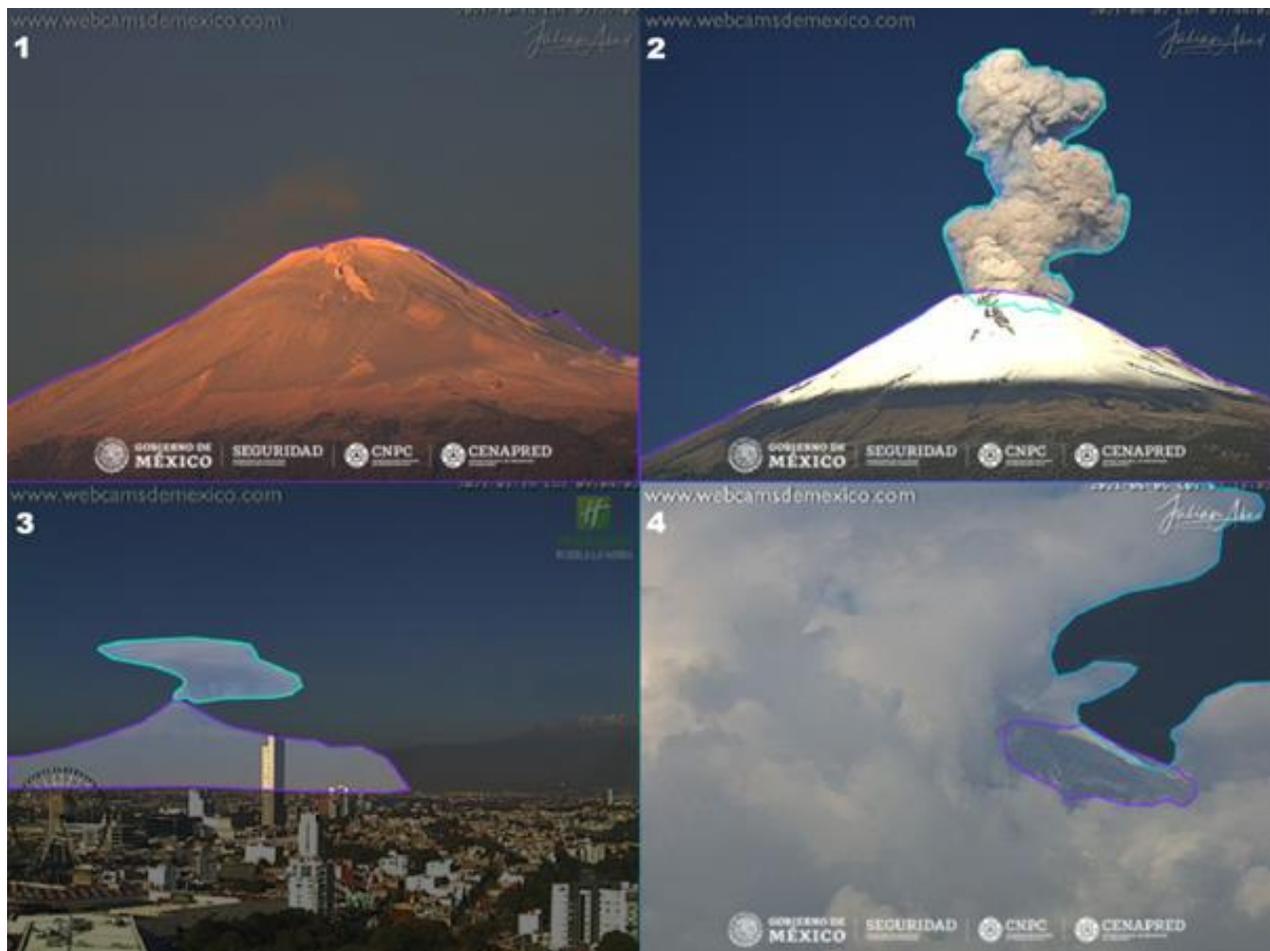


Fig. 2. Ejemplo de imágenes etiquetadas con Roboflow. Se observa la categoría del volcán en calma (1), emisión en condiciones despejadas (2 y 3) y condiciones adversas de nubosidad (4).

Para entrenar este modelo de detección de objetos, se utilizó You Only Look Once versión 8 (YOLOv8) [29]. YOLO es un algoritmo de detección de objetos que conceptualiza el problema como una regresión y busca reducir la complejidad de los procesos al realizarlos a la vez. Funciona de la siguiente manera: una única red convolucional predice simultáneamente varios recuadros delimitadores y las probabilidades de clase de esos recuadros. YOLO se entrena en imágenes completas y optimiza directamente el rendimiento de detección [30]. El entrenamiento se realizó en el servidor de Huawei, pero también se usó la plataforma de Roboflow para entrenar un modelo. Debido a que se usó la versión gratuita, el entrenamiento se pudo hacer únicamente con 400 imágenes. En la Figura 3, se puede apreciar un fotograma de la salida de video con el entrenamiento en Roboflow.



Fig. 3. Fotograma de un video de salida con el modelo de Roboflow. En esta imagen, se muestran tres clases y la probabilidad de que la clase reconocida sea correcta, es decir, la computadora tiene una certeza de 89% de reconocer la nube de ceniza de la imagen.

Resultados

En el caso de clasificación de imágenes de dos categorías (sin actividad, con actividad), se obtuvo una precisión de 98% con los parámetros “activación sigmoïdal”, “optimizador Adam” y con “pérdida entropía cruzada binaria”; para este caso, se tienen dos programas: uno de ejecución lenta y otro de ejecución rápida. En el caso de clasificación de imágenes con tres categorías (sin actividad, gases, ceniza), con activación sigmoïdal, optimizador Adamax y con pérdida entropía cruzada categórica, se obtuvo una precisión de 84%; para este caso, también se tienen dos programas: uno de ejecución lenta y otro de ejecución rápida. En el caso de detección de objetos con YOLOv8, la precisión estuvo apenas por encima de 70%; sin embargo, aunque se tienen 1517 imágenes etiquetadas, este modelo se entrenó con apenas 400 en la plataforma Roboflow de forma gratuita, pero se espera poder hacer el entrenamiento con el conjunto ampliado de datos dentro del servidor de Huawei. Todos estos programas se encuentran en [19].

Aunque la precisión con dos categorías es del 98%, es menor (aunque no se cuantificó) cuando se usa un video en tiempo real, puesto que no se tomó en cuenta el caso donde no hay visibilidad debido a las nubes. En éste, el programa de clasificación de imágenes falla en reconocer si hay actividad o no, dependiendo de qué tan grande sea la nube que cruce por la cámara. Esta variable debe ser tomada en cuenta como una categoría por sí misma al momento de entrenar el modelo para que el cálculo de la imagen arroje que no hay visibilidad. No se ha cuantificado este error en el algoritmo de clasificación de imágenes, pero, en el caso de detección de objetos, sí se ha hecho el etiquetado de nubes que tapan parcial o totalmente la cámara para incorporar esta variable en ese algoritmo.

Conclusiones

La visión computacional ofrece un recurso efectivo para el monitoreo de la actividad volcánica en zonas de difícil acceso o con recursos humanos limitados, además de ser una solución relativamente económica. Actualmente, se ha completado la primera etapa de esta investigación, en la cual se desarrollaron modelos de clasificación con un nivel de precisión adecuado y modelos de detección aún con posibilidades de mejora. De hecho, el error producido intrínsecamente por los modelos se puede reducir de dos formas: mediante un

promedio espacial y uno temporal. En primer lugar, cuando hay nubosidad y poca visibilidad se puede hacer uso de múltiples cámaras: si una cámara no tiene línea de vista, se puede confirmar con otra e incluso se puede hacer un promedio pesado que descarte el resultado arrojado por una o varias de las cámaras (esto ya se está implementando). Además, si la imagen es muy complicada y el modelo tiene una precisión baja, de tal forma que no sabe si es una nube volcánica, se puede esperar a que la nube cambie de forma y volver a cuantificar la imagen unas cuantas veces más algunos segundos más tarde; de esta manera, si el resultado es siempre positivo, se tiene más certeza de lo que está viendo el modelo. En una segunda etapa, se proyecta implementar estos modelos en un entorno de monitoreo en tiempo real accesible al público a través de una plataforma web. Aunque esta aplicación presenta limitaciones inherentes al tipo de fenómeno monitoreado, sus alcances están claramente definidos y representa una herramienta complementaria valiosa para los métodos de monitoreo volcánico existentes.

Agradecimientos

Los autores agradecen al Grupo Especial de Innovación de la DGTIC Alianza-Huawei por la ayuda prestada para la elaboración de este trabajo.

Referencias

- [1] R. Espinasa Pereña, *Historia de la actividad del volcán Popocatepetl, 17 años de erupciones*, 1ra ed. México, D.F.: Secretaría de Gobernación, Cenapred, 2012. [En línea]. Disponible: <https://www.cenapred.unam.mx/es/Publicaciones/archivos/225-HISTORIADELAACTIVIDADELVOLCNPOPOCATPETL-17AOSDEERUPCIONES.PDF>
- [2] A. L. Martin Del Pozzo, et al., "Memoria técnica del mapa de peligros del volcán Popocatepetl, 1ra ed." en *Monografías del Instituto de Geofísica*, no. 22. México, D.F.: Instituto de Geofísica, UNAM, 2017. [En línea]. Disponible: <https://www.geofisica.unam.mx/assets/monografias22.pdf>

- [3] R. Quass Weppen y S. M. Alcocer Martínez de Castro (coords.), *Las cenizas volcánicas del Popocatepetl y sus efectos para la aeronavegación e infraestructura aeroportuaria*, 1era ed. México, D.F.: Secretaría de Gobernación, Cenapred, 2001. [En línea]. Disponible: <https://www.cenapred.unam.mx/es/Publicaciones/archivos/111-LASCENZASVOLCNICASDELPOPOCATPETLYSUSEFECTOSPARALAAERONAVEGACINEI NFRAESTRUCTURAAEROPORTUARIA.PDF>
- [4] H. U. Schmincke, *Volcanism*. Berlin Heidelberg: Springer Verlag, 2004.
- [5] M. Rojas Ramos, H. Noa Ortega, J. Pérez Neria, y J. Villalba Caloca, "Efecto sobre la función pulmonar en personas expuestas a cenizas del volcán Popocatepetl: diciembre 1994-enero 1995", *Rev. Inst. Nac. Enfermedades Respiratorias*, pp. 112–8, 1995.
- [6] R. J. Clarkson, E. J. Majewicz, y P. Mack, "A re-evaluation of the 2010 quantitative understanding of the effects volcanic ash has on gas turbine engines", *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, vol. 230, núm. 12, pp. 2274–2291, oct. 2016, doi: 10.1177/0954410015623372.
- [7] Z. Fanti Gutiérrez, A. Gastelum-Strozzi, E. Hazan-Lasri, y F. Arámbula Cosío, "Aprendizaje computacional aplicado a la detección de huesos, en cirugía ortopédica asistida por computadora", *TIES, Revista de Tecnología e Innovación en Educación Superior*, núm. 4, pp. 1–11, may 2021, doi: 10.22201/dgtic.26832968e.2021.4.5.
- [8] J. L. Morales Reyes, H. G. Acosta Mesa, E. N. Aquino Bolaños, M. D. S. Herrera Meza, N. Cruz Ramírez, y J. L. Chávez-Servia, "Clasificación de poblaciones nativas de frijol utilizando visión artificial", *TIES, Revista de Tecnología e Innovación en Educación Superior*, núm. 4, pp. 1–11, oct. 2021, doi: 10.22201/dgtic.26832968e.2021.4.2.
- [9] L. Bertuccio, M. Coltelli, G. Nunnari, y L. Occhipinti, "Cellular neural networks for real-time monitoring of volcanic activity", *Computers & Geosciences*, vol. 25, núm. 2, pp. 101–117, mar. 1999, doi: 10.1016/S0098-3004(98)00114-9.
- [10] C. D. Martínez, R. C. Uribe, C. Ospina, y R. Vargas Cañas, "Clasificación de imágenes de cámaras de vigilancia volcánica usando visión artificial", *RISTI: Revista Ibérica de Sistemas e Tecnologías de Informação*, núm. Extra 38, pp. 185–198, 2020.

- [11] R. Centeno, V. Gómez-Salcedo, I. Lazarte, J. Vilca-Nina, S. Osoro, y E. Mayhua-Lopez, "Near-real-time multiparametric seismic and visual monitoring of explosive activity at Sabancaya volcano, Peru", *Journal of Volcanology and Geothermal Research*, vol. 451, p. 108097, jul. 2024, doi: 10.1016/j.jvolgeores.2024.108097.
- [12] J. F. Guerrero Tello, M. Coltelli, M. Marsella, A. Celauro, y J. A. Palenzuela Baena, "Convolutional Neural Network Algorithms for Semantic Segmentation of Volcanic Ash Plumes Using Visible Camera Imagery", *Remote Sensing*, vol. 14, núm. 18, Art. núm. 18, ene. 2022, doi: 10.3390/rs14184477.
- [13] S. Korolev, A. Sorokin, I. Urmanov, A. Kamaev, y O. Girina, "Classification of Video Observation Data for Volcanic Activity Monitoring Using Computer Vision and Modern Neural Networks (on Klyuchevskoy Volcano Example)", *Remote Sensing*, vol. 13, núm. 23, Art. núm. 23, ene. 2021, doi: 10.3390/rs13234747.
- [14] T. C. Wilkes, T. D. Pering, y A. J. S. McGonigle, "Semantic segmentation of explosive volcanic plumes through deep learning", *Computers & Geosciences*, vol. 168, p. 105216, nov. 2022, doi: 10.1016/j.cageo.2022.105216.
- [15] Volcanes, webcams en vivo, Webcams de México. Consultado: el 6 de noviembre de 2024. [En línea]. Disponible: <https://webcamsdemexico.com/webcams/volcanes/>
- [16] *Reporte del monitoreo del Cenapred al volcán Popocatepetl*, Cenapred. Consultado: el 6 de noviembre de 2024. [En línea]. Disponible: <https://www.cenapred.unam.mx/reportesVolcanesMX/>
- [17] Observación Volcánica. Consultado: el 6 de noviembre de 2024. [En línea]. Disponible: <https://www.facebook.com/ObervacionVolcanica>
- [18] S. Wang y Z. Su, "Metamorphic Testing for Object Detection Systems", el 19 de diciembre de 2019, *arXiv*: arXiv:1912.12162. doi: 10.48550/arXiv.1912.12162.
- [19] E. Tellez, *erictellez/Popocatepetl_CV*. (el 20 de septiembre de 2024). Jupyter Notebook. Consultado: el 6 de noviembre de 2024. [En línea]. Disponible: https://github.com/erictellez/Popocatepetl_CV

- [20] “¿Qué es el aprendizaje por transferencia?”, IBM, Consultado: el 7 de noviembre de 2024. [En línea]. Disponible: <https://www.ibm.com/es-es/topics/transfer-learning>
- [21] “Keras documentation: MobileNet, MobileNetV2, and MobileNetV3”, Keras Team, Consultado: el 7 de noviembre de 2024. [En línea]. Disponible: <https://keras.io/api/applications/mobilenet/>
- [22] Ringa Tech, *¿Pocos datos de entrenamiento? Prueba esta técnica*, (el 30 de noviembre de 2021). Consultado: el 7 de noviembre de 2024. [Video en línea]. Disponible: https://www.youtube.com/watch?v=9Dur_oUMGG8
- [23] “¿Qué es el sobreajuste?”, IBM. Consultado: el 6 de noviembre de 2024. [En línea]. Disponible: <https://www.ibm.com/mx-es/topics/overfitting>
- [24] “Aumento de datos | TensorFlow Core”, TensorFlow. Consultado: el 8 de noviembre de 2024. [En línea]. Disponible: https://www.tensorflow.org/tutorials/images/data_augmentation?hl=es-419
- [25] “Recursos – Alianza”. UNAM. Consultado: el 30 de junio de 2025. [En línea]. Disponible: <https://alianza.unam.mx/recursos/>
- [26] [26] “tf.keras.preprocessing.image_dataset_from_directory | TensorFlow v2.16.1”, TensorFlow. Consultado: el 8 de noviembre de 2024. [En línea]. Disponible: https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image_dataset_from_directory
- [27] “¿Qué es la detección de objetos?”, IBM. Consultado: el 9 de noviembre de 2024. [En línea]. Disponible: <https://www.ibm.com/mx-es/topics/object-detection>
- [28] “IAPOPO Dataset > Overview”, Roboflow. Consultado: el 9 de noviembre de 2024. [En línea]. Disponible: <https://universe.roboflow.com/ia-popo/ia-popo>
- [29] J. Torres, “YOLOv8 Documentation: A Deep Dive into the Documentation - YOLOv8”. Consultado: el 4 de octubre de 2024. [En línea]. Disponible: <https://yolov8.org/yolov8-documentation/>

- [30] J. Redmon, S. Divvala, R. Girshick, y A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection", el 9 de mayo de 2016, *arXiv*: arXiv:1506.02640. doi: 10.48550/arXiv.1506.02640.