

Predicción de la deformación en la corteza del Volcán Nevado del Ruíz en el año 2020 mediante información troposférica TROPOMI, técnica DInSAR y redes neuronales

Juan Sebastián Hernández Santana

Facultad de Ingeniería de la Universidad Distrital Francisco José de Caldas, Bogotá, Colombia
juashernandezs@correo.udistrital.edu.co

Resumen— El Volcán Nevado del Ruíz situado entre los límites de los Departamentos del Caldas y Tolima en Colombia presentó un comportamiento inestable en el transcurso del año 2020, dicha actividad volcánica conllevó a efectos secundarios en la corteza, es por ello que la predicción de deformaciones se torna como menester de los geocientíficos. En el transcurso de la investigación presentada se dispuso el uso de variables troposféricas, tales como evapotranspiración, índice de aerosoles UV, monóxido de carbono, dióxido de nitrógeno, metano, temperatura superficial, entre otros; para entrenar un conjunto de redes neuronales que puedan predecir el comportamiento de la fase resultante de un interferograma sin desenrollar con la técnica DInSAR, cuyo objetivo principal sea identificar y caracterizar el comportamiento de la corteza con base en las condiciones del entorno. Para lo anterior, se realizó la recolección de variables, la conformación de un modelo lineal generalizado y el conjunto de redes neuronales. Posterior al entrenamiento de la red, se realizó la validación con los datos de testeo, otorgando un MSE de 0,17598 y un r -cuadrado asociado de aproximadamente 0,88454. El modelo resultante permitió la obtención de un conjunto de datos con exactitud temática buena, reflejando el comportamiento del volcán en el año 2020 dado un conjunto de características del ambiente.

Palabras Clave— Deformación de la corteza, TROPOMI, redes neuronales (ANN), actividad volcánica, DInSAR

Recibido: 1 de enero de 2022. Revisado: 3 de abril de 2022. Aceptado: 10 de abril de 2022.

Prediction of crustal deformation of Volcán Nevado del Ruíz in 2020 using TROPOMI tropospheric information, DInSAR technique and neural networks

Abstract— The Nevado del Ruíz volcano, located between the limits of the Departments of Caldas and Tolima, in Colombia, presented an unstable behavior in the course of the year 2020, such volcanic activity led to secondary effects on the crust, which is why the prediction of deformations becomes the task of geoscientists. In the course of this article, the use of tropospheric variables such as evapotranspiration, UV aerosol index, carbon monoxide, nitrogen dioxide, methane, surface temperature, among others, is used to train a set of neural networks that can predict the behavior of the resulting phase of an unrolled interferogram with the DInSAR technique, whose main objective is to identify and characterize the behavior of the crust based on the environmental conditions. For the above, the collection of variables, the conformation of a generalized linear model and the set of neural networks were carried out. After the training of the network, the validation was performed with the test data, giving an MSE of 0,17598 and an associated r -squared of approximately 0,88454. The resulting model allowed obtaining a data set with good thematic accuracy, reflecting the behavior of the volcano in the year 2020 given a set of environmental characteristics.

Keywords— Crustal deformation, TROPOMI, neural networks (ANN), volcanic activity, DInSAR

1 Introducción

La evolución de la tecnología geoespacial ha permitido la caracterización de fenómenos espaciales, tales como, la deformación de la corteza. Una de las mayores contribuciones hace alusión al seguimiento de subsidencias a través del procesamiento DInSAR, utilizando Radar de apertura sintética para interferometría diferencial [41] [46]; por otro lado, el seguimiento de procesos antrópicos, como la minería, también han sido objeto de estudio [1] [46] [48]. Ahora, con base en los datos troposféricos proporcionados por agencias espaciales [2] [8], es posible la aplicación de nuevas metodologías para predecir eventos geográficos, haciendo uso de las propiedades físicas (temperatura, viscosidad, densidad, entre otras) y químicas [25]; no obstante, se debe resaltar que la resolución espacial resultante de dichas mediciones no goza de gran exactitud en estudios de escala grande.

El monitoreo de la actividad volcánica y sus implicaciones en las deformaciones de la corteza se torna como un menester general de las ciencias de la tierra [3] [5]. El primer aspecto a considerar es la topografía asociada a las áreas de estudio, puesto que, en la actualidad, existe gran variabilidad de metodologías para generar productos descriptivos de la realidad, tal como, los modelos digitales de elevación (DEM) o los modelos digitales de superficie (MDS), no obstante, el geocientífico pretende el uso de información comparativamente precisa yuxtapuesta con la evolución tecnológica; como menciona Deng y otros en [9], la generación de modelos de alta resolución contribuye a una mejora considerable de la evaluación del peligro de los volcanes. El segundo aspecto hace alusión a las variables atmosféricas que se pueden medir en las áreas de estudio, tales como, descargas de vapor [10], temperatura en estudios de geoquímica de aguas termales [12], transferencia de calor [27], y demás composiciones geoquímicas producto de eventos sísmicos [47]; dichas variables pueden ser estudiadas de manera local, para escalas de gran detalle, o a escala global, con ayuda de sensores remotos [2] [9], además, dentro de las variables influyentes en las actividades volcánicas se encuentran los cambios químicos sufridos en los escenarios volcánicos [21]. Por otro lado, recientemente, se examinan metodologías para procesos de sinergismos que permitan la caracterización de los valores climáticos de pequeña escala en productos finales de gran

escala, permitiendo, el análisis espacial local con alto grado de proximidad a la realidad.

De acuerdo a lo anterior, el suministro de información espacial permite el desarrollo de nuevos métodos estadísticos aplicados a problemas geográficos, entre ellos, las nacientes tecnologías que involucran la inteligencia artificial, permitiendo la construcción de predicción en escenarios volcánicos no analizados, con base en el entrenamiento de sitios debidamente estudiados [26]. Por consiguiente, el presente artículo pretende el estudio de las deformaciones de la corteza con base en interferogramas sin desenrollar [6] que permitan la identificación de zonas con movimiento en el volcán activo Nevado del Ruíz, utilizando variables troposféricas de múltiples resoluciones espaciales que permitan el entrenamiento de una red neuronal, cuyo fin, sea la predicción de puntos de fase en el intervalo $[-\pi, \pi]$, para sitios con condiciones similares a las encontradas en la zona de estudio.

De igual manera que en el estudio de Alfaro – Sánchez y otros [4] la zona de estudio se caracteriza por la presencia de anillos de árboles alrededor del cráter del volcán, razón por la cual, el cambio químico debe analizarse al momento de determinar las variables independientes, además, dicha información, debe combinarse con condiciones climáticas y actividad fotosintética. Lo anterior, da lugar al procesamiento y análisis de imágenes de satélite, por lo cual, se accedió a un sensor que permitiera la identificación de cambios en las coberturas con base en índices espectrales y, a su vez, presentara concordancia con las demás resoluciones espaciales encontradas, identificando al satélite Landsat 8 con resolución espacial de quince (15) metros y temporal de 16 días como el indicado para el desarrollo de la investigación; algunos estudios, como el de Kumar y otros [18] muestran su eficiencia para determinar los cambios en la dinámica temporal del uso del suelo / cobertura del suelo utilizando el sensor planteado.

En relación al problema expuesto, se dispone la recolección de información vectorial complementaria que vincule factores influyentes en las deformaciones, tales como, la presencia de fallas tectónicas en la zona o recopilación de eventos de riesgo, emitidos por las entidades estatales concernientes a la temática [29] no obstante, la totalidad de la información no fue objeto de uso en el entrenamiento de la red, sino que, contribuyó al posterior análisis de resultados.

2 Revisión de literatura

La revisión del estado del arte es imprescindible para el análisis previo al estudio de subsidencias y la relación entre resultados históricos de la zona de estudio. Lo mencionado de forma previa, favorece la caracterización del sitio a estudiar y las metodologías a utilizar.

2.1 Actividad volcánica en el Volcán Nevado del Ruíz

El Servicio Geológico Colombiano (SGC) encargado del monitoreo constante de los volcanes presentes en el territorio colombiano permite el acceso a boletines informativos mensuales que posibilitan el conocimiento de la actividad

volcánica del nevado; dentro de los aspectos a resaltar, se identificó que, en el boletín 2944 del mes de Mayo de 2020, el volcán – nevado del Ruíz, tenía un comportamiento inestable, sustentado en variaciones geofísicas, geodésicas y geoquímicas, además, que el volcán emitió a la atmosfera cantidades considerables de vapor de agua y gases, entre los cuales, se destacó el dióxido de azufre [32]. La actividad continuo sin cambios drásticos hasta el mes de Julio, sin embargo, en el mes de agosto, se hizo referencia a un aumento (comparativamente considerable al mes debidamente anterior) con relación al número de sismos registrados como en la energía sísmica liberada, dicha proporcionalidad de aumento prosiguió en el mes de octubre y, presentó una reducción en el mes de noviembre, no obstante, en dicho mes, la dinámica de fluidos dentro de los conductos volcánicos aumentó con respecto al mes anterior. En último lugar, el boletín referente al último mes del año 2020, la energía sísmica liberada y el número de sismos registrados presentaron un aumento, al igual que la dinámica de fluidos, por otro lado, los sensores de la NASA registraron variaciones térmicas [33] [34] [35] [36] [37] [38] [39].

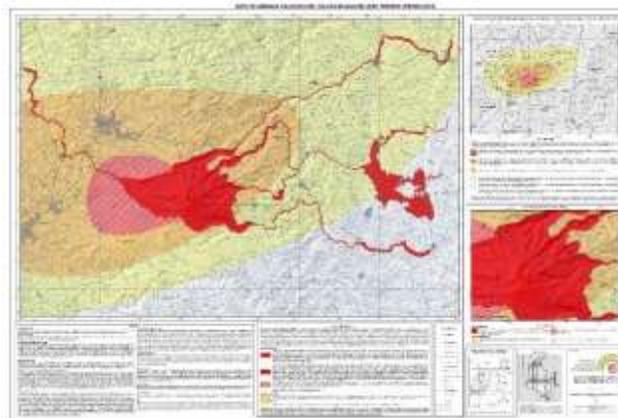


Figura 1. Mapa de amenaza volcánica - Volcán Nevado del Ruíz.
Fuente: Servicio Geológico Colombiano (2015).

La cartografía precedente ilustra las áreas con amenaza volcánica en su tercera versión, donde, las zonas rojas representan zonas con posible afectación por corrientes de densidad piroclástica, proyectiles balísticos, lahares, flujos de lava, avalanchas, onda de choque y gases volcánicos, las zonas naranjas, corresponden a zonas con posible afectación debido a caídas de ceniza y lapilli con acumulaciones entre 1 y 10 cm, con un radio aproximado de 54 km y, finalmente, las zonas amarillas, corresponden a zonas con posible afectación debido a caídas de ceniza y lapilli con acumulaciones entre 0,5 y 1 cm con un radio aproximado de 88 km.

2.2 Reconocimiento de señales de eventos sismo-volcánicos con redes neuronales

Las técnicas de reconocimiento y clasificación se tornan invaluable para el seguimiento de volcanes activos, además, la búsqueda de procesos que ilustren eficacia y eficiencia con el tratamiento de grandes conjuntos de información conlleva al

uso de nuevas metodologías, dentro de las cuales, se encuentra la inteligencia artificial. Martínez y otros [26], ilustran en su investigación denominada “*Advanced signal recognition methods applied to seismo-volcanic events from Planchon Peteroa Volcanic Complex: Deep Neural Network classifier*”, la capacidad de las redes neuronales profundas mediante el uso de parametrizaciones de eventos como una herramienta confiable, fuente de un catálogo sísmico, logrando de esta forma, caracterizar escenarios volcánicos aún no analizados. Lo anterior fue consecuente con el objetivo de esta investigación, puesto que, contempla flujos de trabajo parecidos, más no iguales, para el monitoreo de volcanes.

En adición, investigadores como Tian y otros [43] realizan la predicción asistida de disolución en la corteza volcánica, en su investigación titulada “*Artificial neural network assisted prediction of dissolution spatial distribution in the volcanic weathered crust: A case study from Chepaizi Bulge of Junggar Basin, northwestern China*”, estableciendo parámetros de entrenamiento previo y, realizando la validación correspondiente con el modelo de disolución volcánica geológica proporcionado por la entidad geológica correspondiente. Otro caso de estudio asociado a la temática, es el realizado por Lara y otros [19] con su investigación titulada “*A deep learning approach for automatic recognition of seismo-volcanic events at the Cotopaxi volcano*”, en donde, por medio de reconocimiento automático de micro – terremotos, se realizan predicción en tiempo cercano al real, con base en requerimientos del Instituto Geofísico de la Escuela Politécnica Nacional, con precisión teórica del 97 % en la etapa de clasificación.

2.3 Uso de información derivada de TROPOMI / Sentinel 5 - P

La información troposférica utilizada en la fase de entrenamiento del presente artículo producto de la investigación, se sustenta en gran medida de los datos ofrecidos por el Instrumento de Monitoreo Troposférico (TROPOMI), por lo cual, es pertinente la búsqueda del estado del arte en referencia a dicha fuente de información. La primera investigación consultada, realizada por Shikwambana y otros [40] y titulada “*Trend analysis and first time observations of sulphur dioxide and nitrogen dioxide in South Africa using TROPOMI/Sentinel-5 P data*”, ilustra la capacidad de la información para el análisis de tendencias y observaciones de la información espacial para Sudáfrica, resaltando los aspectos negativos de los contaminantes cuantificados por TROPOMI en términos de la salud humana, el clima y el medio ambiente. En conformidad, la investigación realizada por Wang y otros [45], titulada “*A machine learning model to estimate ground-level ozone concentrations in California using TROPOMI data and high - resolution meteorology*”, expone que, es posible estimar las concentraciones a nivel del suelo para comprender de mejor forma los impactos del ozono en la biodiversidad y la vegetación, mostrando predicciones con valor de r – cuadrado de 0,73, 0,8 y 0,84 de exactitud, valores concernientes con los encontrados en esta investigación.

3 Materiales y métodos

La información del área de estudio, los datos espaciales utilizados y los procedimientos realizados para la predicción de movimiento en forma de fase interferométrica se ilustran a continuación.

3.1 Zona de estudio

La zona de estudio seleccionada para el entrenamiento fue fundamentada en sus características geomorfológicas y troposféricas identificadas, puesto que, puede derivar en la replicabilidad del algoritmo para nuevos casos de estudio, generando la interoperabilidad del código y la posible adición de variables en tiempos cercanos. El Volcán - Nevado del Ruíz, con su forma alargada en dirección Noreste – Suroeste, con un diámetro mayor en su base de 15 kilómetros de longitud, un cráter de 870 x 830 metros de diámetro y profundidad de 247 metros es seleccionado como el escenario óptimo para entrenar el algoritmo de redes neuronales.



Figura 2. Fotografías del Volcán - Nevado del Ruíz.
Fuente: Servicio Geológico Colombiano (2015).

Ubicado en la intersección de 4 grupos de fallas (Palestina, San Jerónimo, Villamaría – Termales, Río Claro, San Eugenio, Campoalegrito, Campoalegre, Nereidas, San Ramón y Santa Rosa), el Volcán – Nevado posee numerosos depósitos de flujos piroclásticos, oleadas piroclásticas, piroclastos de caída y domos, lo cual permite la identificación de deformaciones de la corteza por el comportamiento volcánico de la zona, razón oportuna para hacer uso de la interferometría diferencial SAR (DInSAR), para determinar cambios en la superficie entre dos adquisiciones del radar en fechas de interés (Para el caso de la investigación, Enero, Noviembre y Diciembre del año 2020). Para mayor información de la técnica DInSAR, consultar la investigación de Castellazi y otros [7].

3.2 Datos troposféricos TROPOMI

Lanzado el 13 de Octubre de 2017 el instrumento de Monitoreo Troposférico (TROPOMI) corresponde al sensor satelital a bordo del satélite Copernicus Sentinel – 5 para el estudio de la composición atmosférica, otorgando diversos parámetros, entre ellos, la columna total de ozono, la columna troposférica de ozono, el perfil de ozono, las columnas total y troposférica de dióxido de nitrógeno, la columna total de dióxido sulfúrico, la columna total de monóxido de carbono, la columna total de metano, la columna total de formaldehído, la

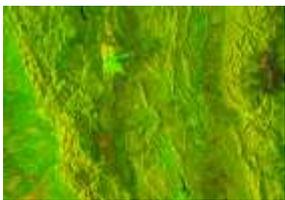
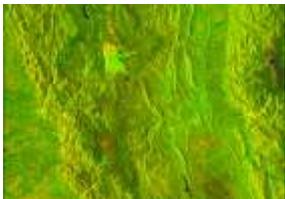
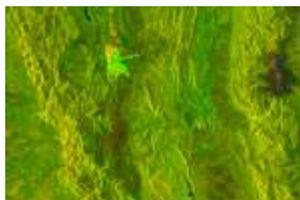
fracción de nubes, albedo y presión superior, el índice de aerosol UV, la altura de la capa de aerosol, la irradiancia superficial, entre otros [2].

Los datos recolectados por el algoritmo planteado en la plataforma Google Earth Engine (GEE) cuentan con una resolución espacial de 1113,2 metros, valor considerablemente bueno, conforme a las variables manejadas por el sensor [2]. Las especificaciones se describen en el ítem de metodología.

3.3 Generación del interferograma sin desenrollar

Con el fin de realizar el interferograma, se hizo uso de 3 productos Sentinel – 1 mostrados en la Tabla 1.

Tabla 1
Imágenes Sentinel utilizadas en la generación del interferograma

Imagen 1		
Fecha de inicio	12/31/20, 10:42:32Z	
Fecha de finalización	12/31/20, 10:42:57Z	
Modo Haz	IW	
Dirección de vuelo	DESCEND	
Órbita absoluta	ING	
Polarización	24945	
	VV+VH	
Imagen 2		
Fecha de inicio	11/25/20, 10:42:34Z	
Fecha de finalización	11/25/20, 10:42:59Z	
Modo Haz	IW	
Dirección de vuelo	DESCEND	
Órbita absoluta	ING	
Polarización	24420	
	VV+VH	
Imagen 3		
Fecha de inicio	01/30/20, 10:42:25Z	
Fecha de finalización	01/30/20, 10:42:50Z	
Modo Haz	IW	
Dirección de vuelo	DESCENDING	
Órbita absoluta	20045	
Polarización	VV+VH	

Fuente: El autor.

El flujo de trabajo permitió la obtención de dos interferogramas sin desenrollar $[-\pi, \pi]$. En primera medida, se realizó el corregistro con los dos pares: enero–noviembre y enero–diciembre, se realizó el producto interferométrico, se realizó la corrección de franjas con S1 Tops Deburst, se realizó la remoción de la fase topográfica, la aplicación del filtro Goldstein, el multilooking, el hallazgo de la fase y la intensidad con la conversión de la información real y compleja y, finalmente, la geocodificación de los datos con aplicación de máscara para evitar zonas de baja coherencia. Del anterior

procedimiento, se identificó mayor coherencia en la zona de estudio.

3.4 Redes neuronales

El paquete utilizado en el Software estadístico R, titulado Neuralnet, el cual, contribuye al entrenamiento de redes neuronales utilizando retropropagación con [30] o sin [31] retroceso de peso, permitiendo la configuración flexible del error y función de activación, aplicando, a su vez, el cálculo de pesos generalizados [17]. Se programaron dos (2) redes ocultas con cinco (5) y tres (3) neuronas respectivamente, con un conjunto de entrenamiento de 5589 puntos de interés, que son descriptores del comportamiento de la fase, según las variables presuntamente explicativas.

4 Metodología

Ahora, se dispone el procedimiento realizado, iniciando con la recolección y procesamiento previo de los datos en la plataforma de Google Earth Engine (GEE), la realización de los procesos interferométricos para obtener el interferograma sin desenrollar, el análisis de la información geográfico para el correspondiente entrenamiento del algoritmo y, finalmente, la codificación de las redes neuronales, cuyo fin es la predicción de deformaciones con base en las fases detectadas en el intervalo $[-\pi, \pi]$.

4.1 Recolección de la información espacial

Con el fin de optimizar almacenamiento local de los equipos de trabajo, se codificó un algoritmo que permitió optimizar la adquisición de la información espacial para un área en específico, donde, se precisó que el trabajo en la nube como respuesta a la rápida búsqueda de información con una unidad de procesamiento gráfico específica para dicho uso sería el flujo más viable. En primera medida, el usuario debe determinar la fecha inicial y final de su interés, realizando un análisis previo de imágenes con porcentaje de altocumulus baja y, sin distorsiones generadas debido al sensor empleado, posteriormente, el algoritmo realiza la búsqueda de las imágenes con base en la nubosidad, el path, el row, la fecha inicial y final de investigación y los intervalos temporales en los cuales, se buscan las imágenes.

Una vez seleccionadas las imágenes, el algoritmo recorta la zona de estudio otorgada por el usuario e inicia con el cálculo de los índices espectrales utilizados dentro del análisis, entre los cuales, se encuentran, el Índice de vegetación de diferencia normalizado (NDVI), el Índice de hojas verdes (GLI), el Índice de clorofila (GCI), entre otros, cuyo fin, es cuantificar el posible cambio de coberturas derivadas de diversas acciones realizadas en el área de estudio. En concordancia con el cálculo anterior, se retira el índice más reciente de la zona (Fecha final del estudio) con la fecha más antigua (Fecha inicial del estudio) para determinar los cambios sufridos en términos de vegetación. Este cálculo se realiza para las dos fechas de estudio (Inicial - Final).

Ahora, con base en la información suministrada por *The European Space Agency* (ESA), se accedió las coberturas presentes en la zona con resolución espacial de diez (10) metros con vigencia del año 2020, dicha información es el resultado del geoprocetamiento de imágenes obtenidas con los sensores Sentinel – 1 y Sentinel – 2 [2]. De la anterior información, se detectaron dos (2) coberturas de gran extensión, la vegetación estéril o escasa y las praderas.

Tabla 2
Atributos de la capa "Cobertura de la tierra".

Valor	Cobertura
10	Árboles
20	Matorral
30	Pradera
40	Tierras de cultivo
50	Construida
60	Vegetación estéril / Escasa
70	Nieve y hielo
80	Agua abierta
90	Humedal herbáceo
95	Manglares
100	Musgo y líquen

Fuente: ESA (2020).

Ahora bien, se recolectó información referente a la evapotranspiración acoplada y el producto primario bruto, cuya disponibilidad se encuentra en el intervalo 2002 – 2017, dicho producto se deriva de los resultados de Penman – Monteith – Leuning, con una resolución de quinientos (500) metros y la información de la Tabla 3. Es oportuno indicar que Los productos Penman – Monteith – Leuning Evapotranspiración V2 (PML_V2) incluyen la evapotranspiración (ET), sus tres componentes, y el producto primario bruto (GPP) con resolución de 500 metros y temporal de 8 días (2002 - 2007).

Tabla 3
Atributos de la capa "Evapotranspiración".

Nombre	Unidades	Min	Max	Descripción
GPP	gC m-2 d-1	0	39,01	Producto primario bruto
Ec	mm d-1	0	15,33	Transpiración de la vegetación
Es	mm d-1	0	8,2	Evaporación del suelo
Ei	mm d-1	0	12,56	Intercepción del dosel de la vegetación
ET_Water	mm d-1	0	20,11	Masa de agua, nieve y evaporación del hielo.

Fuente: Zhang et al., (2019).

Donde los valores máximos son estimaciones, además, el atributo ET_Water utiliza la evapotranspiración de Penman [52] [51] [50]. Es pertinente manifestar que el área cubierta por el conjunto de datos se encuentra entre – 60 ° S y 90 ° N. De manera posterior, se adquirieron los valores del índice de aerosoles UV con resolución de 1113,2 metros, teniendo los datos de la Tabla 4.

Tabla 4
Atributos de la capa "Aerosoles UV".

Nombre	Unidades	Min	Max	Descripción
Absorbing_aerosol_index	-	-21	39	Una medida de prevalencia de aerosoles en la atmósfera.

Fuente: Copernicus Service Information (2021).

Dicha medida de prevalencia, se calcula mediante la ecuación 1.

$$AI = 100 \cdot \log_{10} \left[\frac{R_{media}(x_2)}{R_{media}(x_1)} - 100 \cdot \log_{10} \left[\frac{R_{calc}(x_2, A_{LER}(x_2))}{R_{calc}(x_1, A_{LER}(x_1))} \right] \right] \quad (1)$$

Donde,

$R_{media}(x_2)$ y $R_{media}(x_1)$ son las reflectancias medidas en dos longitudes de onda, siendo $x_2 > x_1$.

$R_{calc}(x_2, A_{LER}(x_2))$ y $R_{calc}(x_1, A_{LER}(x_1))$ son las reflectancias calculadas correspondientes de una atmósfera con solo dispersión de Rayleigh, almacenadas en una LUT precalculada.

$A_{LER}(x_2)$ es la reflectividad equivalente de Lambert (LER) ajustada para la reflectancia x_2 .

[8].

Ahora, se consideró relevante el estudio de la nubosidad en tiempo casi real, con ayuda del Sensor Sentinel 5 – P, con una resolución espacial de 1113,2 metros y, cuyos atributos empleados se presentan en la Tabla 5.

Tabla 5
Atributos de la capa "Nubosidad".

Nombre	Unidades	Min	Max	Descripción
Cloud_fraction	Fraction	0	1	Fración de nube radiométrica efectiva recuperada

Fuente: Copernicus Service Information (2021).

A su vez, se obtuvieron más variables derivadas del sensor Sentinel 5 - P, con una resolución espacial de 1113,2 metros tales como, el monóxido de carbono, el dióxido de nitrógeno, el metano y el dióxido de azufre.

Tabla 6
Atributos de la capas "Monóxido de carbono", "Dióxido de nitrógeno", "Metano" y, "Dióxido de azufre".

Monóxido de carbono				
Nombre	Unidades	Min	Max	Descripción
CO_column_number_density	Mol / m2	-34,43	5,71	Densidad de columna de CO integrada verticalmente.
Dióxido de nitrógeno				
Nombre	Unidades	Min	Max	Descripción

Metano				Descripción
Nombre	Unidades	Min	Max	
NO2_colu mn_number_ _density	Mol / m2	-0.00051	0.0192	Columna vertical total de NO2 (relación entre la densidad de la columna inclinada de NO2 y el factor de masa de aire total).
CH4_colu mn_volume_ _mixing_ra tio_dry_air	ppbV	1491	2352	Proporción de mezcla de aire seco promediada de la columna de metano
Dióxido de azufre				Descripción
Nombre	Unidades	Min	Max	
SO2_colum n_number_ density	Mol / m2	-0.4051	0.2079	Densidad de columnas verticales de SO 2 a nivel del suelo, calculada mediante la técnica DOAS.

Fuente: Copernicus Service Information (2021).

A su vez, se obtuvo la temperatura superficial y el vapor debido a la precipitación del agua para las fechas de estudio, dicha información fue proporcionada por el USGS a través de ECO2LSTE.

Tabla 7

Atributos de las capas "Temperatura superficial" y "Vapor debido a la precipitación del agua".

Nombre	Unidades	Min	Max	Descripción
LST	Kelvin	7500	65535	Temperatura superficial.
PWV	cm	1	65535	Vapor debido a la precipitación del agua.

Fuente: ECO2LSTE (2021).

Con el fin de obtener los mapas de sombreado y aspecto, se hizo uso del SRTM ofrecido por el USGS.

4.2 Generación del interferograma

Con base en la recolección de variables de estudio, se procede a la generación del interferograma para obtener la variable dependiente, en este caso, la fase detectada en el intervalo $[-\pi, \pi]$, cuyo fin, fue la determinación de posibles inflaciones o deflaciones en el terreno conforme su respuesta al sensor en el intervalo temporal de estudio (2019 - 2020).

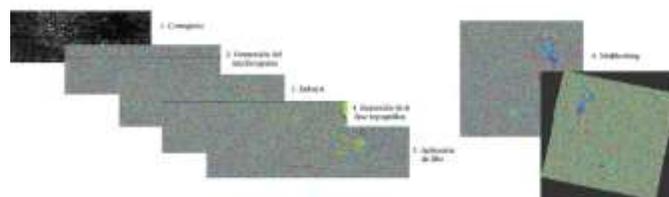


Figura 3. Flujo de trabajo para generación de interferograma. Fuente: El autor.

Es relevante aclarar que la identificación de zonas de uso, presentó concordancia con las áreas cuyo valor de coherencia correspondía a los niveles más altos, debido a la presencia de coberturas específicas, por lo cual, las mediciones que se realicen sobre dicha información, podrían tener confiabilidad del procedimiento realizado.

4.3 Análisis de la información espacial recolectada

Una vez se recolectaron todos los datos, se procedió al estudio de estadística descriptiva de los datos, para comprender su correspondiente tratamiento dentro del entrenamiento de las redes neuronales. El primer factor fue el hallazgo de un modelo lineal generalizado para comprender el comportamiento de las variables sin ningún cambio; con base en dicho modelo, se procede a escalar las variables para una mejor predicción de las redes neuronales, dando como resultado las estadísticas de la Tabla 8. Donde las variables utilizadas se muestran en la Tabla 9.

Tabla 8

Estadísticas de variables utilizadas.

Variable	Mín.	1st Qu.	Mediana	Media	3rd Qu.	Máx.
Col_cm_1	0	0,1116	0,29	0,3447	0,4576	1
Col_df_1	0	0,2558	0,6023	0,5008	0,6887	1
Col_lev_cl	0	0,2339	0,4851	0,4699	0,6705	1
Col_no_1	0	0,3587	0,5169	0,5468	0,7274	1
Col_UV_Aer	0	0,4549	0,6217	0,5906	0,8444	1
B1_data_ev	0	0,03425	0,14644	0,1984	0,31561	1
Dif_EVI	0	0,916	0,916	0,9159	0,916	1
Dif_GCI	0	0,4921	0,4923	0,4921	0,4925	1
Dif_GLI	0	0,4271	0,4272	0,4271	0,4273	1
Dif_NBRI	0	0,401	0,4197	0,437	0,4448	1
Dif_NDVI	0	0,5674	0,5685	0,568	0,5695	1
Dif_RGR	0	0,6123	0,6126	0,6123	0,6129	1
Dif_SAVI	0	0,9713	0,9714	0,9711	0,9714	1
Dif_SIP1	0	0,3321	0,3322	0,3322	0,3323	1
Data_cover	0	0,75	0,75	0,5819	0,75	1
Aspect	0	0,1961	0,3805	0,4201	0,5991	1
Hill_45_315	0	0	0	0,2126	0,4	1
Hill_45_45	0	0	0,3	0,3938	0,8167	1
Hilla_45_135	0	0	0,3167	0,4123	0,85	1
Dir_rad_5	0	0,03819	0,1489	0,26627	0,40063	1
Dis_rad_5	0	0,1814	0,4005	0,4324	0,6658	1
DeI_1st	0	0,255	0,4239	0,46	0,6577	1
DeI_pvw	0	0,198	0,3663	0,4297	0,6436	1
Dist_falla	0	0,07696	0,16239	0,256	0,22252	1
Dir_falla	0	0,3968	0,9429	0,7428	0,9524	1
B2_Fase_Co	0	0,3086	0,3535	0,4043	0,409	1

Fuente: El autor.

Tabla 9
Descripción de variables utilizadas.

Variable	Descripción
Col_cm_1	Colección de información espacial asociada al monóxido de carbono
Col_df_1	Colección de información espacial asociada al dióxido de azufre
Col_lev_cl	Colección de información espacial asociada a la nubosidad
Col_no_1	Colección de información espacial asociada al óxido de nitrógeno
Col_UV_Aer	Colección de información espacial asociada al índice de aerosoles UV
B1_data_ev	Colección de información espacial asociada al producto primario bruto
Dif_EVI	Diferencia del índice espectral EVI
Dif_GCI	Diferencia del índice espectral GCI
Dif_GLI	Diferencia del índice espectral GLI
Dif_NBRI	Diferencia del índice espectral NBRI
Dif_NDVI	Diferencia del índice espectral NDVI
Dif_RGR	Diferencia del índice espectral RGR
Dif_SAVI	Diferencia del índice espectral SAVI
Dif_SIP1	Diferencia del índice espectral SIP1
Data_cover	Coberturas del terreno
Aspect	Mapa de pendientes
Hill_45_315	Sombreado con altitud 45 ° y acimut 315 °
Hill_45_45	Sombreado con altitud 45 ° y acimut 45 °
Hilla_45_135	Sombreado con altitud 45 ° y acimut 135 °
Dir_rad_5	Dirección de radiación
Dis_rad_5	Distancia de radiación
Del_1st	Cambio en la temperatura superficial
Del_pvw	Cambio en el vapor por agua precipitada
Dist_falla	Distancia a la falla más cercana
Dir_falla	Dirección a la falla más cercana
B2_Fase_Co	Valor de la fase en el intervalo $[-\pi, \pi]$

Fuente: El autor.

Con la información debidamente organizada y, escalada, se procedió al entrenamiento de las redes neuronales.

4.4 Creación de las redes neuronales y predicción

Con base en el análisis de la información y las librerías ofrecidas por el Software R, se realizó una red neuronal cuya variable dependiente es el valor en radianes de la fase y las variables exploratorias se conforman de las veintiséis (26) ilustradas en la Tabla 9, se tomaron 2 redes ocultas, con cinco (5) y tres (3) neuronas correspondientemente.

Conforme a los resultados, se pretendió la comparación entre el modelo lineal generalizado calculado anteriormente, y los resultados de la red, analizando los gráficos de predicción, los MSE y el r – cuadrado asociado.

5 Resultados

Se obtuvieron 26 archivos ráster remuestreados con los valores correspondientes a las variables expuestas en la Tabla 9. Previo a la utilización de los datos, se realizó el correspondiente hallazgo de valores para cada punto de muestra; dicha posición espacial correspondía a la posición (x, y) del ráster de mejor resolución espacial.

5.1 Organización de la información

Posteriormente, se programó el respectivo algoritmo de recolección de la información espacial según la posición de la muestra en el lenguaje Python con la librería ArcPy.

5.2 Interferogramas

Los interferogramas muestran alta coherencia en función de la fase sin desenrollar, en la zona de estudio (Nevado del Ruíz), no obstante, se seleccionó el alusivo al intervalo temporal Enero – Diciembre, puesto que este tenía mayor cantidad de área y mostraba mayor número de deformaciones.

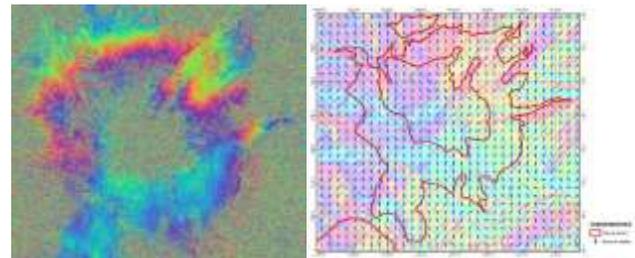


Figura 4. Subzona de estudio con alta coherencia
Fuente: El autor.

En el costado norte del Volcán – Nevado del Ruíz se puede identificar un acercamiento al sensor en una proporción considerable de la zona de estudio, demostrando un sollevamiento -levantamiento progresivo de la corteza- de dicha zona y, una subsidencia -hundimiento progresivo durante un periodo extenso que permite la acumulación de grandes espesores de sedimentos- en la subzona inferior de la previamente identificada como aquella con valores de coherencia altos. En el costado sur, se evidencia nuevamente un alejamiento al sensor, demostrando una subsidencia considerablemente más alta que la evidenciada en el costado norte.

5.3 Escalado de variables

En términos de la información recolectada, se realizó el escalado de las variables, por medio de los parámetros de escala: valor máximo menos valor mínimo, con centro en el valor mínimo, dando como resultado distribuciones más confortables que la información previa al entrenamiento de las redes neuronales (Fig. 5). Dicho escalado de variables permitió una mejor predicción de los datos y, por consiguiente, un mejor ajuste del modelo realizado por la red neuronal. Lo anterior se sustenta en las mediciones de calidad realizadas para el modelo lineal generalizado previo y posteriori al proceso de escalamiento.

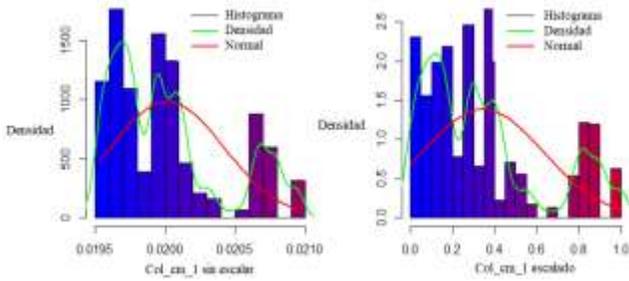


Figura 5. Ejemplo de escalado de la variable “Monóxido de carbono”
Fuente: El autor.

5.4 Redes neuronales

En primera medida, el modelo lineal generalizado otorgó la significancia de dieciséis (16) variables al 0,1%, entre las cuales, destacan, el monóxido de carbono, el dióxido de azufre, porcentaje de nubosidad, aerosoles UV, el cambio en la temperatura superficial, el cambio en el vapor derivado de la precipitación del agua y, los productos derivados del Modelo Digital de Superficie (MDE). La variable de menos significancia es la radiación, por lo cual, se excluyeron de las variables seleccionadas para el entrenamiento de las redes neuronales. Por otro lado, el MSE derivado del modelo generalizado es de aproximadamente, 1,5241.

Ahora, con las variables escaladas con centro en el valor mínimo, y siendo el parámetro de escala la diferencia entre el valor máximo y mínimo, se realiza la composición del grupo de datos para entrenamiento y para validación, siendo la proporción 75 % y 25 % respectivamente. La red neuronal resultante se ilustra a continuación:

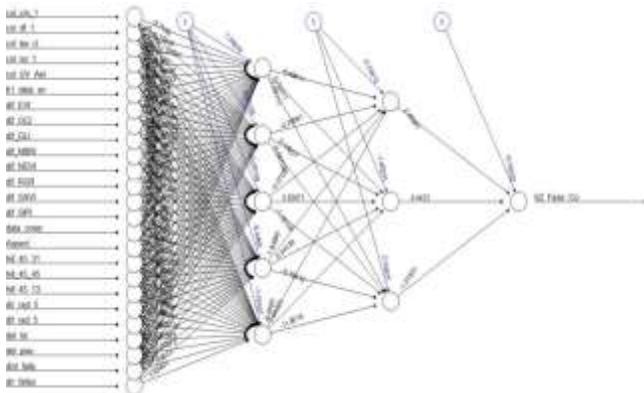


Figura 6. Red neuronal resultante.
Fuente: El autor.

Posterior al entrenamiento de la red, se realiza la validación con los datos restantes, otorgando un MSE de 0,17598 y, un r -cuadrado asociado de aproximadamente, 0,88454.

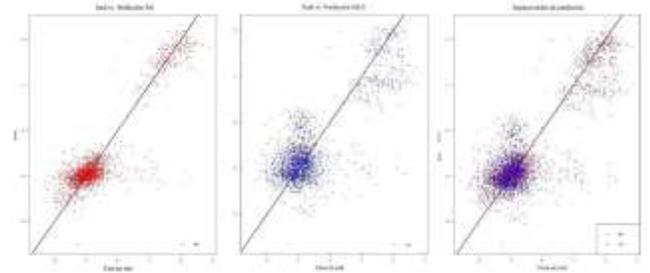


Figura 7. Gráficos de predicción y comparativa entre modelo lineal generalizado y redes neuronales.
Fuente: El autor.

Al graficar los valores reales versus los datos predichos, se identifica la mejoraría en la calidad de predicción, además, es compatible con el estadístico calculado (88,45 %). Algunos de los resultados espaciales se ilustran en la Fig. 6.

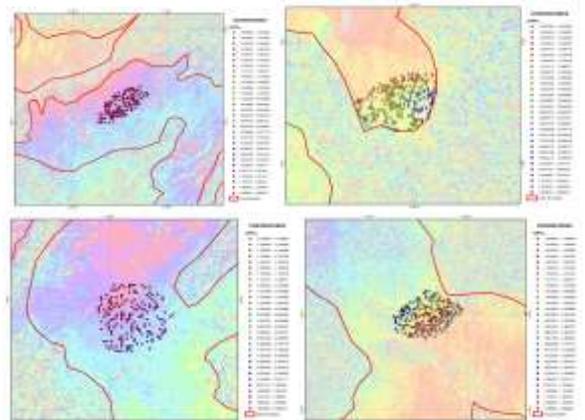


Figura 6. Subzonas de predicción con puntos de validación.
Fuente: El autor.

En la ilustración anterior, se observan algunas de las predicciones realizadas por las redes neuronales, en donde, se ilustran cambios del terreno en el intervalo $[-\pi, \pi]$.

6 Discusión

La contribución de las redes neuronales en la predicción de la deformación en la corteza es evidente, pues permitió un mejor ajuste del modelo, ilustrando resultados de mayor exactitud estadística y temática. Lo anterior, se evidencia en las medidas estadísticas resultantes y la espacialización de los puntos de testeo, ya que, al ser superpuestos por la capa explicada, demuestran similitud, en términos de la expresada por los boletines del Servicio Geológico Colombiano para el año 2020.

Tal como nombra Alfaro-Sánchez y otros [4] el aumento en la concentración de elementos metálicos se evidencio con la significancia de las variables troposféricas obtenidas de TROPOMI, lo cual, permite inferir que el procedimiento puede ser replicable conforme se actualizan las fechas de inicio y fin de la investigación y, la información recolectada por los sensores. A su vez, se distingue la significancia del cambio en la actividad de la vegetación, demostrado en los diferenciales

de los índices utilizados en la codificación de Google Earth Engine.

Las relaciones ilustradas en investigaciones [11] [14] [23] [49] en términos de la presencia de fallas en las deformaciones de la corteza, presentan coherencia con la significancia de las dos (2) variables utilizadas en el modelo, referentes a la distancia y dirección a la falla más cercana al punto estudiado; ahora, esto contribuye al menester de contar con información geológica debidamente organizada, actualizada y libre, cuyo fin, sea la generación de nuevos productos relevantes entorno a la gestión del riesgo y el monitoreo de la deformación en la corteza. Las redes neuronales mostraron un comportamiento inverso de la distancia a la falla más cercana con la deformación de la corteza, mientras, la dirección a dicha falla demostró una relación directa.

Por otro lado, la significancia de los diferenciales en la temperatura superficial y el vapor por agua precipitada, se premeditaba, dado los diversos resultados de investigaciones previas, como, las expuestas por Yang y otros [47], Vélez y otros [44], Moreno y otros [27] o Gómez Díaz & Mariño Arias [12]. Los resultados del modelo lineal generalizado manifiestan una relación inversa entre el valor de la fase y los diferenciales de temperatura y vapor, mientras que, las redes neuronales manifiestan una relación directa, lo cual, conlleva a inferir el correcto aprendizaje de las redes con la base de datos suministrada.

El entrenamiento de redes neuronales para predicción de deformación, puede ser complementado con técnicas de mayor precisión, tal como, las realizadas por Gómez – Arango et al. [13], Hajra et al. [15], Inguaggiato et al. [16], Li [20], Londono [22], Londoño y Kumagai [24], entre otros, derivando en resultados con mayor respaldo estadístico. A su vez, la calidad de predicción puede presentar una mejoría según la capacidad del equipo a trabajar, pues, esto permitirá un entrenamiento más exhaustivo, con mayor número de redes ocultas y por consiguiente, mayor número de neuronas.

En términos de las deformaciones identificadas, se manifiesta el acercamiento al sensor en una proporción considerable de la zona norte del volcán, demostrando un solevamiento de dicha zona y, una subsidencia en la subzona inferior de la previamente identificada como aquella con valores de coherencia altos, manifestando la relación con los boletines mensuales realizados por el Servicio Geológico Colombiano para el año 2020, en términos del aumento de eventos sísmicos y emisión de gases; es por ello, que la utilización de las variables troposféricas cobró importancia en el entrenamiento de las redes.

7 Conclusiones

El procedimiento expuesto es replicable dentro de los límites geográficos del sensor fuente de información troposférica. No obstante, es pertinente ahondar y alimentar la información de entrenamiento con más variables que permitan un nivel más alto de predicción, de forma tal, que los valores espacializados puedan complementar los resultados otorgados por la interferometría diferencial SAR (DInSAR). A su vez,

augmentar el número de redes ocultas y neuronas puede aumentar el nivel de exactitud estadística y temática. Por otro lado, la información espacial relacionada con el componente geológico, debe ser tratada con precaución, puesto que, de dichos datos se derivarán variables que entrenarán futuros modelos, tales como, la distancia y dirección a la falla más cercana.

Como se ilustra en diversas investigaciones, entre ellas, Niraj et al. [28], Acosta et al. [1], Brasca Merlín et al. [6], Deng et al. [9], Singh et al. [42], Yao et al. [48], la interferometría diferencial SAR permite el acceso a una análisis eficiente de las deformaciones en la corteza, no obstante, se debe resaltar que dicha técnica presenta dificultades en coberturas boscosas, como las presentes en la zona de estudio, razón por la cual, el entrenamiento en el volcán – Nevado del Ruíz permitió obtener zonas de alta coherencia, que a su vez, habilitaría la exploración de más geofomas con condiciones similares.

Referencias

- [1] G. Acosta et al., «Detection of active landslides by DInSAR in Andean Precordillera of San Juan, Argentina», *Journal of South American Earth Sciences*, vol. 108, p. 103205, jun. 2021, doi: 10.1016/j.jsames.2021.103205.
- [2] ESA) Agencia Espacial Europea, «Data products Tropomi», dic. 31, 2021. <http://www.tropomi.eu/data-products>
- [3] K. S. Ajithabh y P. K. Patro, «Crustal deformation in Volcanic covered area as inferred from magnetotelluric studies: An example from India», *Journal of Geodynamics*, vol. 145, p. 101840, may 2021, doi: 10.1016/j.jog.2021.101840.
- [4] R. Alfaro-Sánchez, J. J. Camarero, J. I. Querejeta, J. Sagra, D. Moya, y D. A. Rodríguez-Trejo, «Volcanic activity signals in tree-rings at the treeline of the Popocatepetl, Mexico», *Dendrochronologia*, vol. 59, p. 125663, feb. 2020, doi: 10.1016/j.dendro.2020.125663.
- [5] J. Blahůt y J. Klimeš, «Causes and Triggers of Mass-Movements: Volcanic Activity», en Reference Module in Earth Systems and Environmental Sciences, Elsevier, 2021. doi: 10.1016/B978-0-12-818234-5.00121-8.
- [6] A. Brasca Merlín et al., «DInSAR and statistical modeling to assess landslides: The case study of Sierras Chicas (central Argentina)», *Journal of South American Earth Sciences*, vol. 108, p. 103179, jun. 2021, doi: 10.1016/j.jsames.2021.103179.
- [7] P. Castellazzi et al., «Land subsidence in major cities of Central Mexico: Interpreting InSAR-derived land subsidence mapping with hydrogeological data», *International Journal of Applied Earth Observation and Geoinformation*, vol. 47, pp. 102-111, may 2016, doi: 10.1016/j.jag.2015.12.002.
- [8] Copernicus Sentinel Data, «For Sentinel data: Sentinel-5P», dic. 21, 2021. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-5p>
- [9] F. Deng et al., «High-resolution DEM generation from spaceborne and terrestrial remote sensing data for improved volcano hazard assessment — A case study at Nevado del Ruíz, Colombia», *Remote Sensing of Environment*, vol. 233, p. 111348, nov. 2019, doi: 10.1016/j.rse.2019.111348.
- [10] C. Federico, S. Inguaggiato, Z. Chacón, J. M. Londoño, E. Gil, y D. Alzate, «Vapour discharges on Nevado del Ruíz during the recent activity: Clues on the composition of the deep hydrothermal system and its effects on thermal springs», *Journal of Volcanology and Geothermal Research*, vol. 346, pp. 40-53, oct. 2017, doi: 10.1016/j.jvolgeores.2017.04.007.
- [11] M. Feng et al., «Crustal seismogenic structures and deformation styles along the Longmen Shan Fault belt in the eastern Tibetan Plateau inferred from ambient noise tomography», *Tectonophysics*, vol. 798, p. 228689, ene. 2021, <https://doi.org/10.1016/j.tecto.2020.228689>
- [12] E. Gómez Díaz y O. M. Mariño Arias, «Structural assessment and geochemistry of thermal waters at the Cerro Machin Volcano (Colombia): An approach to understanding the geothermal system», *Journal of Volcanology and Geothermal Research*, vol. 400, p. 106910, ago. 2020,

- doi: 10.1016/j.jvolgeores.2020.106910.
- [13] J. A. Gómez-Arango, H. Murcia, y C. Borrero, «Finding eruptive mechanisms through pyroclasts from the current eruption (1984–present) at Nevado del Ruiz Volcanic Complex, Colombia», *Journal of Volcanology and Geothermal Research*, vol. 364, pp. 48-58, sep. 2018, doi: 10.1016/j.jvolgeores.2018.09.003.
- [14] S. Guo, G. Zhang, y Y. Zhu, «Gravity changes and crustal deformations before the Menyuan, Qinghai Ms6.4 earthquake of 2016», *Geodesy and Geodynamics*, vol. 10, n.º 4, pp. 315-320, jul. 2019, doi: 10.1016/j.geog.2019.03.007.
- [15] S. Hajra, D. Hazarika, S. Mondal, S. K. Pal, y P. N. S. Roy, «Deformation of the upper crust in the Kumaon Himalaya analyzed from seismic anisotropy and gravity lineament studies», *Physics of the Earth and Planetary Interiors*, vol. 322, p. 106827, ene. 2022, doi: 10.1016/j.pepi.2021.106827
- [16] S. Inguaggiato, J. M. Londoño, Z. Chacón, M. Liotta, E. Gil, y D. Alzate, «The hydrothermal system of Cerro Machín volcano (Colombia): New magmatic signals observed during 2011–2013», *Chemical Geology*, vol. 469, pp. 60-68, oct. 2017, doi: 10.1016/j.chemgeo.2016.12.020
- [17] O. Intrator y N. Intrator, «Using Neural Nets for Interpretation of Nonlinear Models. Proceedings of the Statistical Computing Section», San Francisco: American Statistical Society (eds), pp. 244-249, 1993.
- [18] P. Kumar, M. Dobriyal, A. Kale, y A. K. Pandey, «Temporal dynamics change of land use/land cover in Jhansi district of Uttar Pradesh over past 20 years using LANDSAT TM, ETM+ and OLI sensors», *Remote Sensing Applications: Society and Environment*, vol. 23, p. 100579, ago. 2021, doi: 10.1016/j.rsase.2021.100579.
- [19] F. Lara, R. Lara-Cueva, J. C. Larco, E. V. Carrera, y R. León, «A deep learning approach for automatic recognition of seismo-volcanic events at the Cotopaxi volcano», *Journal of Volcanology and Geothermal Research*, vol. 409, p. 107142, ene. 2021, doi: 10.1016/j.jvolgeores.2020.107142
- [20] Y. Li, «Analysis of GAMIT/GLOBK in high-precision GNSS data processing for crustal deformation», *Earthquake Research Advances*, vol. 1, n.º 3, p. 100028, jul. 2021, doi: 10.1016/j.eqrea.2021.100028.
- [21] Q. Liu, D. Zhu, Z. Jin, Q. Meng, y S. Li, «Influence of volcanic activities on redox chemistry changes linked to the enhancement of the ancient Sinian source rocks in the Yangtze craton», *Precambrian Research*, vol. 327, pp. 1-13, jul. 2019, doi: 10.1016/j.precamres.2019.02.017.
- [22] J. M. Londoño, «Evidence of recent deep magmatic activity at Cerro Bravo-Cerro Machín volcanic complex, central Colombia. Implications for future volcanic activity at Nevado del Ruiz, Cerro Machín and other volcanoes», *Journal of Volcanology and Geothermal Research*, vol. 324, pp. 156-168, sep. 2016, doi: 10.1016/j.jvolgeores.2016.06.003.
- [23] J. M. Londoño y Y. Sudo, «Velocity structure and a seismic model for Nevado del Ruiz Volcano (Colombia)», *Journal of Volcanology and Geothermal Research*, pp. 61-87, 2021, doi: [https://doi.org/10.1016/S0377-0273\(02\)00306-2](https://doi.org/10.1016/S0377-0273(02)00306-2).
- [24] J. M. Londoño y H. Kumagai, «4D seismic tomography of Nevado del Ruiz Volcano, Colombia, 2000–2016», *Journal of Volcanology and Geothermal Research*, vol. 358, pp. 105-123, jun. 2018, doi: 10.1016/j.jvolgeores.2018.02.015.
- [25] JM. Marreo y A. L. Ortiz, «Dirección general de protección civil y emergencias.» s.f.
- [26] V. L. Martínez et al., «Advanced signal recognition methods applied to seismo-volcanic events from Planchon Peteroa Volcanic Complex: Deep Neural Network classifiers», *Journal of South American Earth Sciences*, vol. 107, p. 103115, abr. 2021, doi: 10.1016/j.jsames.2020.103115.
- [27] D. Moreno, J. Lopez-Sanchez, D. Blessent, y J. Raymond, «Fault characterization and heat-transfer modeling to the Northwest of Nevado del Ruiz Volcano», *Journal of South American Earth Sciences*, vol. 88, pp. 50-63, dic. 2018, doi: 10.1016/j.jsames.2018.08.008.
- [28] K. C. Niraj, S. K. Gupta, y D. P. Shukla, «Kotrapi landslide deformation study in non-urban area using DInSAR and MTInSAR techniques on Sentinel-1 SAR data», *Advances in Space Research*, dic. 2021, doi: 10.1016/j.asr.2021.11.042.
- [29] G. Paris y J. A. R. L., «Fallas activas en Colombia», *Boletín Geológico*, vol. 34, n.º 2-3, Art. n.º 2-3, jul. 1994.
- [30] M. Riedmiller, «Rprop—Description and Implementation Details», 1994. <https://www.scirp.org/%28S%28351jmbntvnsjt1aadkposzje%29%29/reference/referencespapers.aspx?referenceid=52366>
- [31] M. Riedmiller y H. Braun, «A direct adaptive method for faster backpropagation learning: the RPROP algorithm», en *IEEE International Conference on Neural Networks*, mar. 1993, pp. 586-591 vol.1. doi: 10.1109/ICNN.1993.298623.
- [32] Servicio Geológico Colombiano, «Boletín informativo No. 2944 del mes de mayo de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [33] Servicio Geológico Colombiano, «Boletín informativo No. 2945 del mes de junio de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [34] Servicio Geológico Colombiano, «Boletín informativo No. 2946 del mes de julio de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [35] Servicio Geológico Colombiano, «Boletín informativo No. 2947 del mes de agosto de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [36] Servicio Geológico Colombiano, «Boletín informativo No. 2948 del mes de septiembre de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [37] Servicio Geológico Colombiano, «Boletín informativo No. 2949 del mes de octubre de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [38] Servicio Geológico Colombiano, «Boletín informativo No. 2950 del mes de noviembre de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [39] Servicio Geológico Colombiano, «Boletín informativo No. 2951 del mes de diciembre de 2020 con referencia a la actividad volcánica del segmento norte de Colombia.» 2020.
- [40] L. Shikwambana, P. Mhangara, y N. Mbatha, «Trend analysis and first time observations of sulphur dioxide and nitrogen dioxide in South Africa using TROPOMI/Sentinel-5 P data», *International Journal of Applied Earth Observation and Geoinformation*, vol. 91, p. 102130, sep. 2020, doi: 10.1016/j.jag.2020.102130.
- [41] B. S. Simmons y J. M. Wempfen, «Quantifying relationships between subsidence and longwall face advance using DInSAR», *International Journal of Mining Science and Technology*, vol. 31, n.º 1, pp. 91-94, ene. 2021, doi: 10.1016/j.ijmst.2020.12.021.
- [42] G. Singh, B. R. Nela, D. Bandyopadhyay, S. Mohanty, y A. V. Kulkarni, «Discovering anomalous dynamics and disintegrating behaviour in glaciers of Chandra-Bhaga sub-basins, part of Western Himalaya using DInSAR», *Remote Sensing of Environment*, vol. 246, p. 111885, sep. 2020, doi: 10.1016/j.rse.2020.111885.
- [43] M. Tian, H. Xu, J. Cai, J. Wang, y Z. Wang, «Artificial neural network assisted prediction of dissolution spatial distribution in the volcanic weathered crust: A case study from Chepaizi Bulge of Junggar Basin, northwestern China», *Marine and Petroleum Geology*, vol. 110, pp. 928-940, dic. 2019, doi: 10.1016/j.marpetgeo.2019.08.045.
- [44] M. I. Vélez, D. Blessent, S. Córdoba, J. López-Sánchez, J. Raymond, y E. Parra-Palacio, «Geothermal potential assessment of the Nevado del Ruiz volcano based on rock thermal conductivity measurements and numerical modeling of heat transfer», *Journal of South American Earth Sciences*, vol. 81, pp. 153-164, ene. 2018, doi: 10.1016/j.jsames.2017.11.011.
- [45] W. Wang, X. Liu, J. Bi, y Y. Liu, «A machine learning model to estimate ground-level ozone concentrations in California using TROPOMI data and high-resolution meteorology», *Environment International*, vol. 158, p. 106917, ene. 2022, doi: 10.1016/j.envint.2021.106917.
- [46] J. M. Wempfen, «Application of DInSAR for short period monitoring of initial subsidence due to longwall mining in the mountain west United States», *International Journal of Mining Science and Technology*, vol. 30, n.º 1, pp. 33-37, ene. 2020, doi: 10.1016/j.ijmst.2019.12.011.
- [47] X. Yang et al., «The impact of volcanic activity on the deposition of organic-rich shales: Evidence from carbon isotope and geochemical compositions», *Marine and Petroleum Geology*, vol. 128, p. 105010, jun. 2021, doi: 10.1016/j.marpetgeo.2021.105010.
- [48] X. Yao et al., «Average-DInSAR method for unstable escarpments detection induced by underground coal mining», *International Journal of Applied Earth Observation and Geoinformation*, vol. 103, p. 102489, dic. 2021, doi: 10.1016/j.jag.2021.102489.
- [49] J. Zhang, Z. Wu, Z. Shen, C. Dong, C. Wang, y Y. Zhao, «Seismic evidence for the crustal deformation and kinematic evolution of the Nansha Block, South China Sea», *Journal of Asian Earth Sciences*, vol.

203, p. 104536, nov. 2020, doi: 10.1016/j.jseae.2020.104536.

- [50] L. Zhang, S. Liang, X. Yang, y C. Dai, «The migration of the crustal deformation peak area in the eastern Himalayan Syntaxis inferred from present-day crustal deformation and morpho-tectonic markers», *Geodesy and Geodynamics*, vol. 12, n.º 3, pp. 165-174, may 2021, doi: 10.1016/j.geog.2021.02.002.
- [51] Y. Zhang et al., «Estimación acoplada de 500 my evapotranspiración global con resolución de 8 días y primaria bruta producción en 2002-2017», *Ambiente Sens. Remoto*, pp. 165-182, 2019, doi: <https://doi.org/10.1016/j.rse.2018.12.031>.
- [52] Y. Zhang et al., «Tendencias multidecenales en la evapotranspiración terrestre global y sus componentes.», *Sci. Rep.* 6, p. 19124, 2016, doi: <https://doi.org/10.1038/srep19124>.

J. S. Hernández Santana es Profesional en Ciencias de la Tierra e Ingeniería, con énfasis en el análisis y procesamiento de información espacial, con aplicación en Sistemas de Información Geográfica, Cartografía, Programación, Procesamiento digital de imágenes, Ciencia de datos espaciales y Analítica espacial. Orientado a la Ingeniería de datos, visualización y exploración, análisis espacial (Detección de patrones espaciales, analítica espacio – temporal, analítica predictiva, modelos de idoneidad, optimización de procesos, planeación de rutas, análisis de terrenos), *Machine learning* e IA, Big data, modelamiento y código, para la generación de proyectos y reportes. Miembro del semillero pensamiento espacial y análisis territorial vinculado al grupo NIDE del proyecto curricular de Ingeniería Catastral y Geodesia de la Universidad Distrital Francisco José de Caldas.

<https://orcid.org/0000-0002-8782-6803>