



La Inteligencia Geoespacial Aplicada a la Interferometría Radar: Una Revisión

Alejandro Oro^[1], Ayelen Pereira^[2]

[1] Área de Fotogrametría, Facultad de Ingeniería, Universidad Nacional de San Juan, CPA: J5400ARL, San Juan, Argentina

[2] Área de Geodinámica y Geofísica, Facultad de Ciencias Exactas, Ingeniería y Agrimensura, CPA: S2000BTP, Rosario, Argentina.

[1] alejandro.seryn@gmail.com

[2] ayeppereira@gmail.com

Abstract Synthetic Aperture Radar Interferometry (InSAR) is a widely used technique in various sciences such as remote sensing, geodesy, seismology, volcanology, among others, with highly diverse applications. Some of these include estimating surface subsidence or uplift, post-seismic deformation, and creating digital elevation models. In the modern digital era, Artificial Intelligence (AI) and Machine Learning (ML) are revolutionizing many fields of knowledge, with a wide range of uses, from urban planning to the optimization of productive tasks. Broadly speaking, geospatial intelligence (GI) refers to the utilization of AI in the field of geospatial data. In this context, and given the vast number of areas covered by GI, this study focuses on the application of GI in the field of InSAR. To this end, a comprehensive review of the current state of the art was conducted, analyzing both supervised and unsupervised ML techniques tested on real and synthetic datasets. The aim is to contribute to understanding the current possibilities and limitations of AI-assisted interferometric processing. The study presents cases in urban and rural environments, identifying the most common themes in the use of GI in InSAR, the ML methods employed, and the conclusions drawn. It can be anticipated that, in general, the authors studied preferred supervised ML methods over unsupervised ones, with most of these studies being concentrated in Asia. Finally, it is worth noting that among all the currently available satellite images, those from the Sentinel-1 satellite were the most preferred for conducting these investigations.

Resumen La interferometría de radar de apertura sintética (por sus siglas en inglés InSAR) es una técnica ampliamente utilizada en muchas ciencias tales como la percepción remota, la geodesia, la sismología, la vulcanología, entre otras, con aplicaciones muy variadas. Algunas de ellas son: la estimación de la subsidencia o el levantamiento de la superficie, la deformación post sísmica o la creación de modelos digitales de terreno. En la era digital moderna, la inteligencia artificial (IA) y el machine learning (ML) están revolucionando muchísimos campos del saber, con variados usos, desde la planificación urbana hasta la optimización de tareas productivas. En términos generales, se entiende por inteligencia geoespacial (IG) al aprovechamiento de la IA en el campo de los datos geoespaciales. En este sentido, y debido a la enorme cantidad de áreas del conocimiento que abarca la IG, para este trabajo se ha acotado el análisis a la aplicación de la IG en el campo de la InSAR. Para esto se realizó una revisión exhaustiva del estado del arte actual, analizando tanto técnicas supervisadas como no supervisadas de ML, probadas sobre conjuntos de datos reales y sintéticos. Con esto se pretende realizar una contribución acerca de las posibilidades y limitaciones actuales del procesamiento interferométrico asistido por IA. Se presentan casos en ámbitos urbanos y rurales, identificando los temas más comunes de la utilización de la IG en InSAR, los métodos de ML empleados y las conclusiones a las que se arribó. Se puede adelantar que, en general, los autores estudiados prefirieron los métodos de ML supervisados por sobre los no supervisados, ubicándose la mayoría de

estos trabajos en oriente. Finalmente destacar que, de todas las imágenes disponibles actualmente, fueron las del satélite Sentinel-1 las preferidas para llevar adelante estas investigaciones.

Palabras clave: Inteligencia Geoespacial, DInSAR, Interferometría Radar, Inteligencia Artificial, Machine Learning, Revisión.

Keywords: Geospatial Intelligence, DInSAR, Radar Interferometry, Artificial Intelligence, Machine Learning, Review.

1 Introducción

El avance de la inteligencia artificial (IA) ha revolucionado múltiples áreas del conocimiento debido a su capacidad para procesar, analizar y extraer información valiosa a partir de una vasta cantidad de datos geoespaciales, marcando un hito en cómo entendemos y aprovechamos nuestro entorno. Su uso ha mejorado notablemente la precisión de los análisis espaciales y ha desencadenado innovaciones sin precedentes en la toma de decisiones estratégicas y en la comprensión de complejas interrelaciones entre los elementos geográficos, dando origen a la creación de un nuevo campo del saber: la inteligencia geoespacial (IG). Este campo del conocimiento se centra en la recopilación, análisis y visualización de datos geográficos para obtener información significativa sobre el mundo que nos rodea. Esta disciplina tiene aplicaciones en una amplia gama de campos gracias a su capacidad para potenciar la detección de patrones y tendencias en un conjunto de datos espaciales. En particular, la interferometría SAR o InSAR es una técnica utilizada para la generación de modelos digitales de terreno y el monitoreo de deformaciones de la superficie a partir de imágenes de satélite radar [26] y [33]. La Interferometría Diferencial (por sus siglas en inglés DInSAR) explota la fase del SAR que es sensible a los cambios de elevación ocurridos sobre la superficie del terreno entre distintas imágenes obtenidas por un satélite sobre una misma zona [19], [44] y [45]. Si la topografía del terreno es conocida, es decir si se dispone de un modelo digital de terreno, la correspondiente componente de fase puede ser sustraída de la fase InSAR, dejando la componente relacionada con la deformación del terreno; esto hace posible la detección de pequeñas deformaciones de la superficie terrestre con una precisión del orden de centímetros.

DInSAR, que en forma creciente se aplica al estudio de las deformaciones cosísmicas y post sísmicas [12] y [45], compara la información de fase de dos imágenes SAR tomadas en el área epicentral de un sismo, una antes y otra después del evento. La diferencia de fases resultante origina un nuevo tipo de imagen denominada interferograma. De producirse la deformación del terreno, el interferograma muestra un modelo de interferencia formado por franjas (fringes) que contienen toda la información sobre la geometría relativa entre las dos imágenes [30]. Cada franja indica un cambio de la distancia suelo-satélite de 28 mm. Esta gran precisión permite el estudio de las deformaciones originadas por terremotos de magnitudes moderadas ($M \sim 4$ a 5) que de otro modo resultan imperceptibles en los estudios de terreno. Esta técnica ha sido utilizada en Argentina para conocer la dinámica de los glaciares, terremotos, volcanes, deslizamientos y subsidencias asociadas a la explotación de acuíferos así como para actividades mineras y petroleras, entre otros [21], [23], [37] y [38]. También se ha utilizado para medir la deformación del terreno vinculada a sismos de moderada a alta magnitud como los de Sichuan, en China en 2008 (MW 7,9) [69], L'Aquila, Italia en 2009 [74], para caracterizar procesos de deformación volcánica y movimiento de glaciares [73] y [24], entre otros ejemplos. Por otro lado, [22] han utilizado técnicas de InSAR para el cálculo de rumbo y buzamiento de estructuras no aflorantes.

La recopilación de publicaciones estudiadas para este trabajo abarca diversas aplicaciones de IA y el ML en el campo de la InSAR y las geociencias. Se han revisado una amplia variedad de publicaciones, desde guías paso a paso para el procesamiento de imágenes Sentinel-1 usando ML hasta enfoques innovadores en los que se explora el uso de redes generativas adversariales (GAN) para el desenrollado de fase a fin de mejorar la precisión de resultados de la interferometría diferencial de radar de apertura sintética, con el fin de brindar una revisión detallada del estado del arte de la aplicación de la IG en los procesamientos interferométricos.

La aplicación de técnicas de aprendizaje automático (ML) a la interferometría radar (InSAR) ha demostrado ser un campo emergente con el potencial de mejorar significativamente la precisión en la detección de deformaciones geológicas. Este estudio revisa y compara enfoques que abordan esta problemática, proporcionando una visión integral sobre el estado del arte. El análisis de los enfoques híbridos, que combinan aprendizaje supervisado y no supervisado, revela su potencial para superar las limitaciones de los métodos tradicionales en la identificación de

patrones en datos geoespaciales. A través de este trabajo, se expone cómo estos métodos podrían mejorar el rendimiento en escenarios con datos limitados. Y si bien se han logrado avances, persisten importantes vacíos en la literatura, particularmente en lo que respecta a la estandarización de evaluaciones de modelos y la integración efectiva de datos multi-sensor. Por eso, este trabajo no solo identifica estos vacíos, sino que también propone nuevas líneas de investigación que podrían cambiar el rumbo del campo.

2 Materiales y métodos

Esta sección describe el procedimiento y los métodos que se han seguido para elaborar esta revisión, y dado que el objetivo es estudiar el uso de la IG en el ámbito de la InSAR y sus numerosas aplicaciones, se optó por realizar una revisión de alcance. Esta última metodología se ha desarrollado para brindar un mapeo de los dominios de estudio, fuentes de datos, enfoques y métodos [54]. Si bien las revisiones de alcance son relativamente nuevas en comparación con las revisiones sistemáticas, se han establecido como una herramienta ideal para determinar la extensión de un cuerpo de literatura emergente y proporcionar una visión general de su enfoque [49]. En este caso, una revisión de alcance es adecuada porque el número de publicaciones sobre las aplicaciones de IG para InSAR ha crecido rápidamente en los últimos años y, por lo tanto, es imposible llevar a cabo una revisión sistemática rigurosa sin excluir aspectos del campo.

2.1 Planificación de la revisión de alcance: Criterio de elegibilidad

La IG y la InSAR son campos muy amplios. Por esta razón, se decidió utilizar los siguientes criterios para seleccionar los documentos relevantes para el análisis sobre las aplicaciones de la IG en el procesamiento de imágenes de radar de apertura sintética (SAR):

- 1) Los documentos seleccionados emplearon principalmente algoritmos de IA o ML para mejorar la eficiencia de los procesamientos interferométricos o disminuir sus limitaciones. Se incluyeron métodos de ML supervisados y no supervisados. Por otro lado, se excluyeron aquellas publicaciones que utilizaron polarimetría SAR o que solo discutieron aspectos teóricos del ML.
- 2) Los documentos que se utilizaron para este análisis emplearon conjuntos de datos geoespaciales, específicamente, imágenes provenientes de satélites con capacidades interferométricas o interferogramas sintéticos. Por ejemplo, se incluyeron documentos que utilizaron imágenes satelitales ópticas en combinación con modelos digitales de terreno u otros datos geoespaciales.
- 3) Se incluyeron documentos que se centraron en teledetección, detección de objetos y características geoespaciales a partir de imágenes satelitales, procesamiento de imágenes y clasificación de imágenes.
- 4) Los documentos seleccionados eran de libre acceso.

2.2 Búsqueda y selección en la base de datos

Para identificar un grupo inicial de literatura para este estudio, se utilizó el buscador de Google a fin de garantizar una amplia cobertura multidisciplinaria. En la literatura, los términos InSAR y DInSAR se utilizan a menudo de manera intercambiable, aunque no son exactamente lo mismo. De cualquier manera, estas dos metodologías son relevantes para esta revisión, por lo que se optó por incluir ambos términos en la búsqueda. Por otro lado, cabe destacar que el término ‘inteligencia geoespacial’ no solo se refiere al uso de la IA aplicada a los datos geoespaciales, sino que en algunos contextos es empleado para describir el aprovechamiento de datos espaciales para la seguridad nacional, tal como lo define la Agencia Nacional de Inteligencia Geoespacial (National Geospatial-Intelligence Agency) de Estados Unidos, situada en Springfield, Virginia. Finalmente, cabe mencionar que se tuvo en cuenta que la mayoría de las publicaciones están en idioma inglés. Debido a esto, se utilizó como palabras clave para la búsqueda: ‘artificial intelligence’, ‘machine learning’, ‘deep learning’, ‘InSAR’ y ‘DInSAR’. Luego, se examinaron los resultados con el enfoque de solo excluir libros sobre la materia, ya que los mismos son en su mayoría pagos y suelen encarar la temática desde el punto de vista teórico o didáctico. En contrapartida, se conservaron para el análisis, las publicaciones en estado de preprint, los resúmenes y las conferencias. De los cientos de documentos encontrados, se seleccionaron 54 que cumplían con todos los criterios de elegibilidad. Este conjunto de artículos fue recopilado en enero de 2024.

2.3 Revisión y análisis

Después de seleccionar los artículos según los criterios de elegibilidad presentados en la sección anterior, se analizó el cuerpo de literatura, seleccionando información clave en los documentos: título, autores, año de publicación, el propósito del estudio, lugar del estudio de caso, el método utilizado, datos informados, información de entrenamiento-prueba y parámetros. Para el mapeo de temas y métodos, se recopiló la información en tablas mediante el análisis de cada documento. Si un documento no proporcionaba información sobre un detalle específico, se lo registró como ausente en dicha categoría. Este flujo de trabajo puede verse representado en la figura 1.

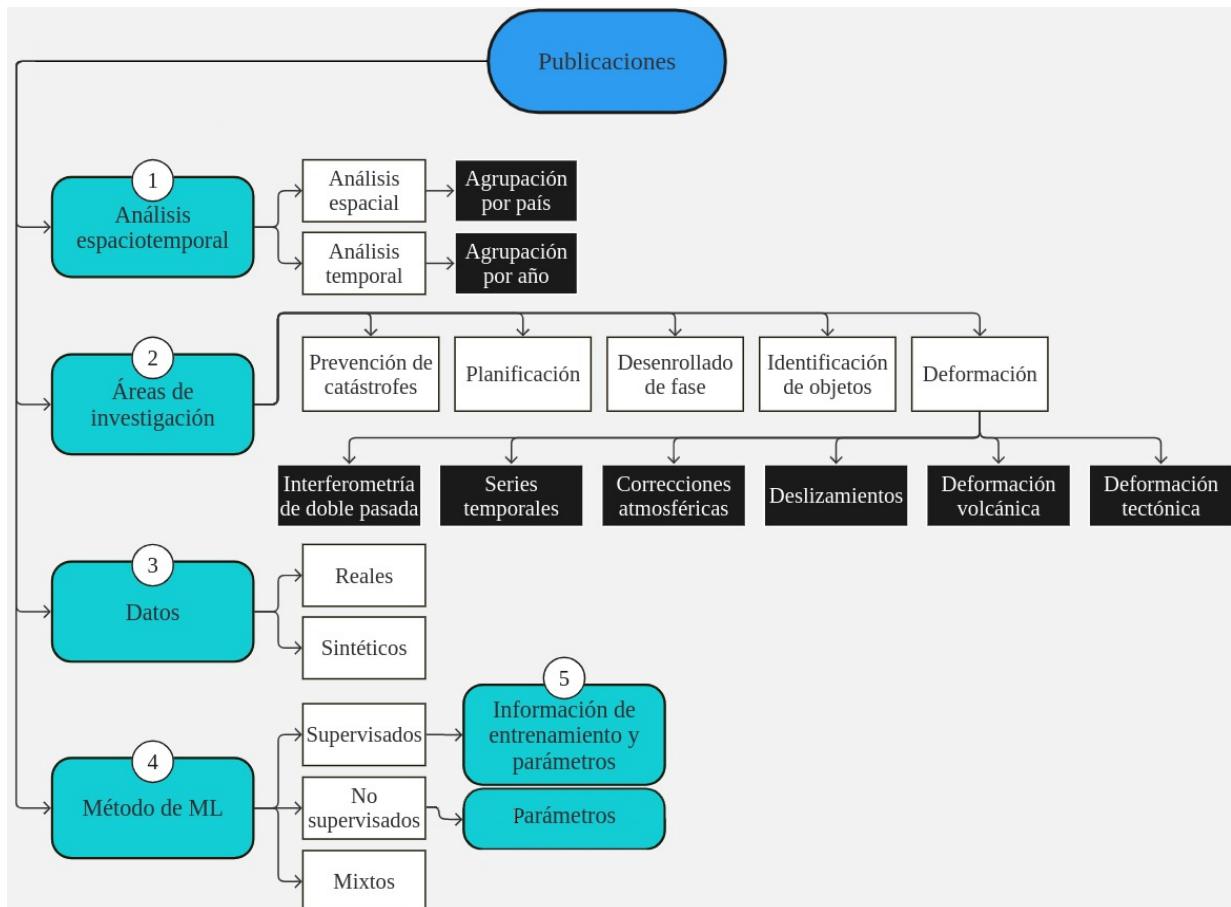


Figura 1. Diagrama de flujo del proceso de análisis realizado para cada una de las publicaciones estudiadas.

El análisis cubrió cinco perspectivas:

- 1) Se investigó la distribución espacial y temporal de los documentos. Para los análisis espaciales, se agruparon por país las ubicaciones de los casos de estudio.
- 2) Se mapearon los temas estudiados en los documentos para identificar áreas de investigación prioritarias y brechas. Se desarrollaron cinco categorías de estudios que representan los temas más comunes de la interferometría radar: prevención de catástrofes, planificación, desenrollado de fase, identificación de objetos y deformación. A esta última categoría se la desglosó en seis sub-categorías: interferometría de doble pasada, series temporales, correcciones atmosféricas, deslizamientos, deformación volcánica y deformación tectónica.
- 3) Para identificar patrones en el uso de los datos se investigó el tipo de datos que los documentos utilizaron para desarrollar sus modelos. Se distinguió entre datos reales y sintéticos, y entre aquellos provenientes de satélites ópticos y de radar.

4) Para mapear los métodos de ML más destacados en cada categoría de estudio, se analizaron los métodos utilizados. Se distinguieron los métodos de ML según supervisados, no supervisados, una combinación de no supervisados y supervisados. No se analizó si se usaron algoritmos de procesamiento de lenguaje natural (NLP) debido a que la información derivada de datos SAR no es lingüística, sino que generalmente se generan imágenes raster.

5) Se analizó la información de entrenamiento y los parámetros informados a fin de estudiar cómo los autores implementaron sus análisis y reportaron la información asociada, en aquellos casos donde se emplearon métodos supervisados.

2.3.1 Comparación entre distintos enfoques

Como se ha visto hasta ahora, existen tres enfoques principales en el uso de IA en InSAR:

a) Modelos supervisados: requieren grandes volúmenes de datos etiquetados y han demostrado ser efectivos en la detección de deformaciones. Son precisos, pero dependen en gran medida de la calidad del entrenamiento y pueden tener dificultades para generalizar a nuevas condiciones geográficas.

b) Modelos no supervisados: son más flexibles, ya que pueden detectar patrones ocultos sin necesidad de datos etiquetados. Sin embargo, su interpretación es más compleja y su validación más difícil, lo que puede generar resultados menos confiables en algunos escenarios.

c) Modelos semi-supervisados: combinan elementos de aprendizaje supervisado y no supervisado para aprovechar las fortalezas de ambos. Estos modelos pueden mejorar la precisión al incorporar datos no etiquetados en el entrenamiento supervisado, pero aún están en desarrollo y requieren más investigación para su implementación efectiva.

Un análisis comparativo sugiere que los modelos semi-supervisados poseen el mayor potencial, al combinar lo mejor de los enfoques supervisados y no supervisados. Sin embargo, su complejidad y la necesidad de ajustes específicos para cada caso siguen siendo limitaciones importantes. A partir de la revisión bibliográfica, se identifican varios vacíos en la literatura actual: la falta de estandarización en la evaluación de modelos de aprendizaje automático aplicados a InSAR; la escasa exploración de técnicas de IA en contextos con datos limitados o con alto nivel de ruido; y la necesidad de validaciones empíricas más sólidas que respalden los métodos propuestos en estudios anteriores. Además, son pocos los trabajos que analizan el impacto de la combinación de datos ópticos y radar en la mejora de la precisión interferométrica. Finalmente, la aplicación de modelos semi-supervisados en escenarios geoespaciales reales continúa siendo incipiente, lo que abre un campo prometedor para investigaciones futuras.

2.3.2 Profundización del Análisis

En esta sección se destacan algunas las principales dificultades de los enfoques de ML existentes. Para empezar, los modelos híbridos destacan por combinar la robustez del aprendizaje supervisado con la flexibilidad del aprendizaje no supervisado. Son prometedores porque pueden mejorar la detección de deformaciones en áreas con escasos datos clasificados. Sin embargo, los enfoques semi-supervisados también emergen como una alternativa clave, ya que permiten la optimización del modelo sin depender excesivamente de datos etiquetados manualmente. Por otro lado, la falta de datasets estandarizados y comparables que permitan evaluar objetivamente los modelos, y la dependencia de grandes volúmenes de datos etiquetados sigue siendo un obstáculo en entornos con escasez de información. A su vez, los modelos de ML aplicados a InSAR aún carecen de interpretabilidad, lo que dificulta su adopción en entornos operativos. La variabilidad en la calidad y resolución de los datos de radar puede afectar la precisión del ML. Adicionalmente, la fusión de datos provenientes de sensores ópticos y de radar todavía presenta dificultades en la normalización y alineación espacial. La implementación de modelos robustos que puedan generalizarse a diferentes regiones y condiciones geográficas sigue siendo un reto significativo.

3 Resultados

3.1 Distribución espacial y temporal

De todos los documentos analizados, 51 especificaban la ubicación de la zona de estudio mientras que los 4 restantes no la mencionaban, ya sea porque el estudio tiene un enfoque metodológico, o porque solo se usaron datos sintéticos. La figura 2 muestra la distribución de los estudios de casos por país y a lo largo del tiempo, resaltando claramente la discrepancia entre las regiones. La mayoría de los casos se encuentran en China, Italia y Estados Unidos, seguidos por Irán, Etiopía y España. En general, el 15% de los estudios estaban en América del Norte, el 12,5% en Europa y el 7,5% en Asia. Cinco documentos incluyen múltiples casos de estudio en diferentes países, y nueve de ellos en diferentes continentes. Si un documento cubría varios estudios de casos, se contaba cada estudio de caso por separado y se lo asignaba al continente respectivo. En la figura 2, las barras muestran el año de publicación de los documentos. Aproximadamente el 70% de los documentos se publicaron entre 2021 y 2023, lo que indica la creciente popularidad del campo.

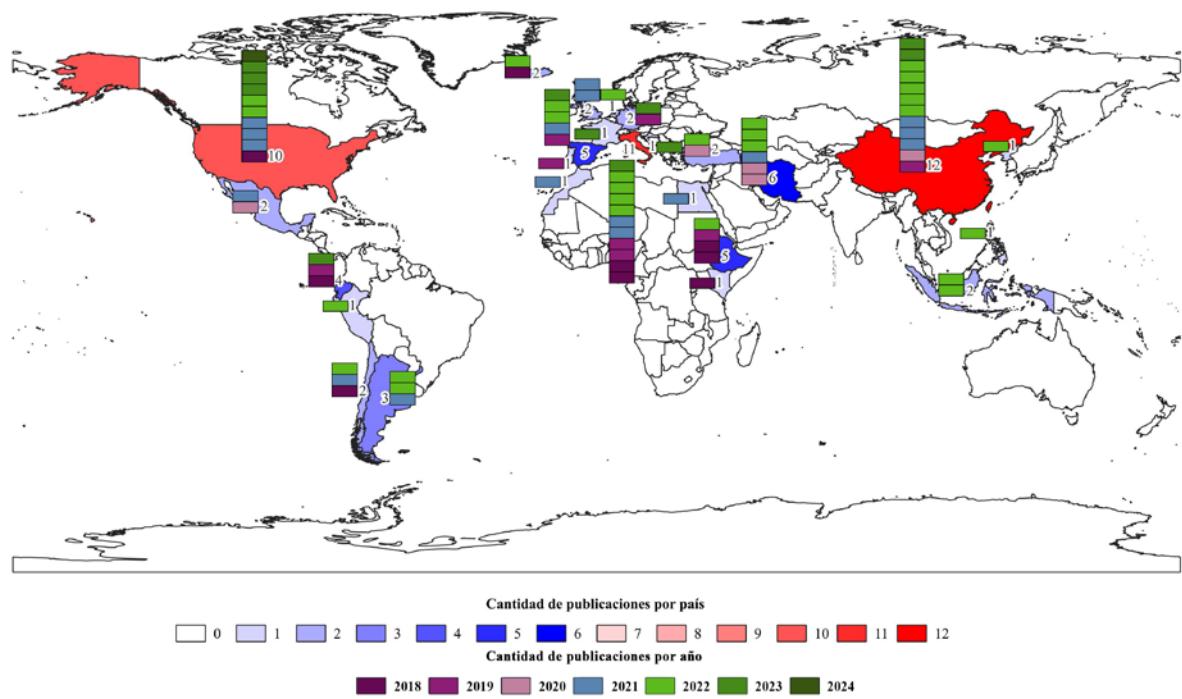


Figura 2. Distribución espacial y temporal de las publicaciones. El mapa muestra la distribución de los casos de estudio por país y las barras muestran los años de publicación.

3.2 Categorías

Para derivar las categorías temáticas, se analizaron las temáticas más relevantes en los estudios que aplican interferometría (figura 3). Como el foco fueron los atributos espaciales, se omitieron aquellos datos vectoriales complementarios como usos del suelo, modelos digitales del terreno, etc. Para capturar también la importancia de los factores ambientales y sus peligros, se incluyeron dos categorías, una correspondiente a la prevención de catástrofes y otra a la planificación. Se descubrió que 54 documentos están dedicados a la detección de la deformación del terreno usando diferentes métodos, 9 documentos abordan la prevención de catástrofes, 5 proponen

métodos para mejorar el desenrollado de la fase SAR, 3 documentos se enfocan en la detección de objetos y solo 1 está abocado a la planificación. Dado que la categoría Deformación concentra una cantidad significativamente mayor de estudios y representa el núcleo temático más desarrollado, se decidió realizar un análisis más profundo de sus subcategorías en la siguiente sección. Una discusión más detallada de los resultados obtenidos para cada categoría se desarrolla en la sección 4.

3.2.1 Deformación

Se identificaron 6 subcategorías dentro de los estudios que analizan la deformación de la superficie mediante DInSAR (54 documentos). Estos se centran principalmente en el uso de series temporales (30 documentos) y en la interferometría de doble pasada (10 documentos). Se observó que las correcciones atmosféricas (5 documentos), los deslizamientos de suelo (3 documentos), la detección de deformación volcánica (5 documentos) y la detección de deformación sísmica (4 documentos) fueron temáticas abordadas en menor medida. El uso de series temporales permitió estudiar tendencias en deslizamientos, deformación volcánica y deslizamientos, combinando las capacidades de análisis que brindan la IA y el ML para mejorar la precisión en la extracción de patrones de estos resultados interferométricos. De manera similar, la interferometría de doble pasada se utilizó para detectar y caracterizar la deformación superficial, mientras que una variedad de algoritmos de IA se aplicaron para mitigar los efectos atmosféricos sobre las señales de radar.

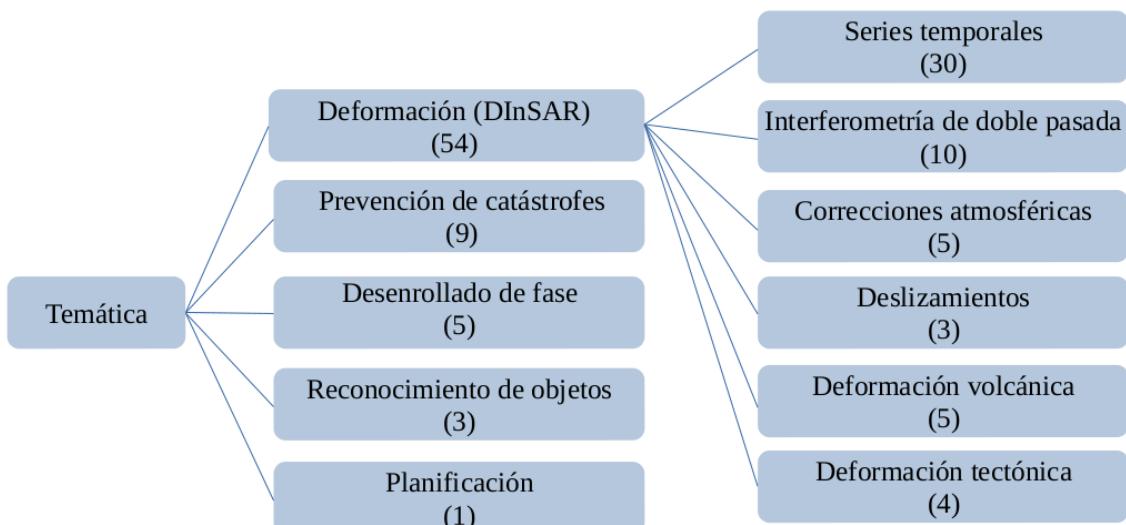


Figura 3. El gráfico de árbol muestra los principales temas de investigación. Se indica el número de documentos por categoría entre paréntesis. Algunos documentos abarcan más de una categoría.

3.3 Datos

Los estudios de aprendizaje automático revelan información crítica y oculta en conjuntos de datos. Para el análisis sobre los datos subyacentes, se comenzó con una visión general de la frecuencia con la que se utilizaron diferentes tipos de datos. Se distinguió entre datos reales y sintéticos, imágenes ópticas y radares. La figura 4 muestra un histograma de los datos de entrada a lo largo de las diferentes categorías temáticas. Se enumeraron los datos utilizados en al menos dos documentos en orden alfabético.

Los datos más populares fueron los del satélite Sentinel-1 (60,6%), que además de ser usualmente utilizados para realizar interferometría diferencial, son de libre acceso. A estos les siguen las imágenes COSMO-SkyMed (7%), que además de permitir realizar interferometría, poseen capacidad estereoscópica y se utilizaron principalmente para análisis de series temporales y la prevención de catástrofes, pero también en estudios ambientales e infraestructuras (figura 4). Como era de esperar, los datos ópticos (4,2%; MSG-0, TripleSat y Landsat 8) fueron más prominentes en la categoría Series temporales ya que se usaron para mapear los usos del suelo, la extensión de deslizamientos y de volcanes, sirviendo como un complemento a los análisis DInSAR.

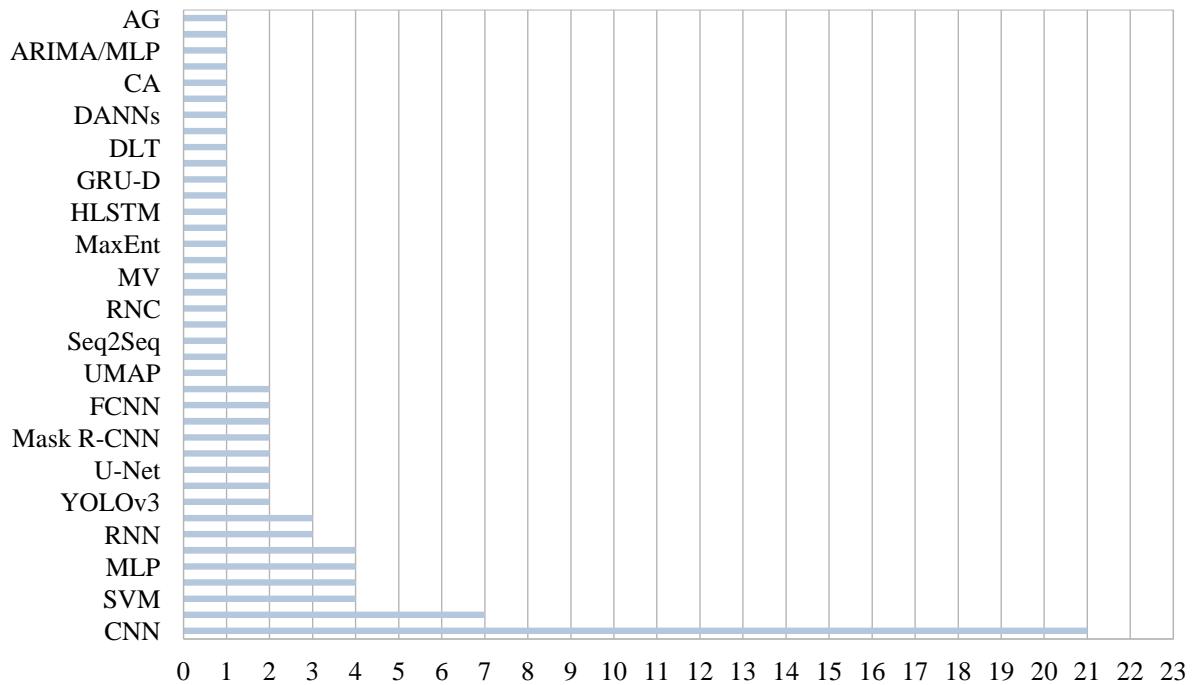


Figura 4. Histograma de los datos e imágenes satelitales usadas para las aplicaciones de IG en interferometría radar. MSG-0: Meteosat Second Generation. Aqua, Terra y Aura son satélites de la NASA para la observación del agua, la superficie terrestre y los gases atmosféricos a nivel mundial, respectivamente.

En cuanto a la longitud de onda de las señales (figura 5), los radares en banda X (74,55%) se utilizaron con mayor frecuencia para la detección de deformación y, con menos frecuencia, para estudios sobre la prevención de catástrofes. También fueron los más usados para el reconocimiento de objetos y los estudios sobre desenrollado de fase. Aunque los datos de banda S y L están ganando importancia, especialmente en lo que respecta a interferometría diferencial y prevención de catástrofes , encontramos que dichos datos aún no se utilizan con frecuencia ya que solo el 3,64% de los documentos los utilizaron. Finalmente, en cuanto a los datos ópticos, estos fueron utilizados principalmente para estudiar el desplazamiento del suelo como en los casos de deslizamientos.

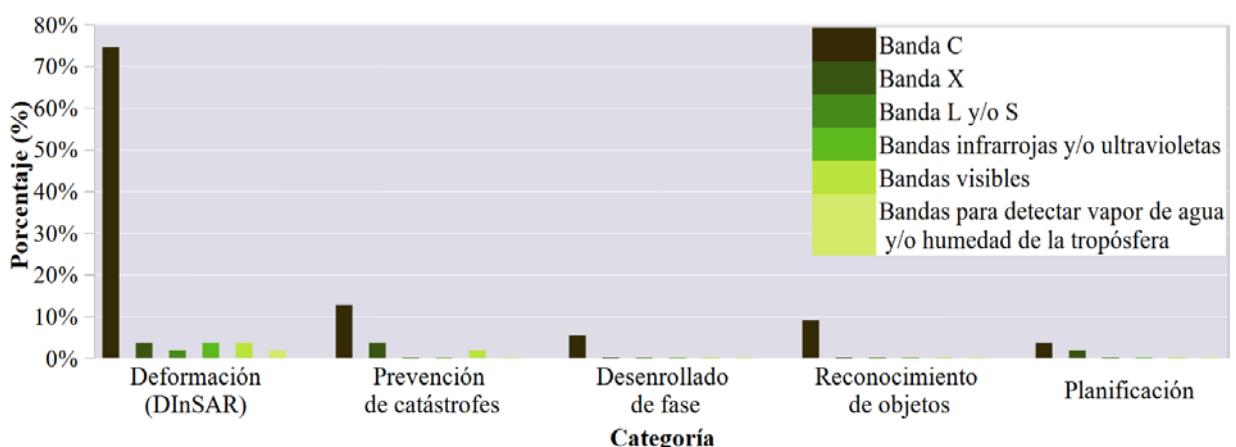


Figura 5. Tipo de datos de los sensores remotos por tema. El histograma muestra el porcentaje de publicaciones que usaron imágenes en bandas C, X, L y/o S, infrarrojas y/o ultravioletas, visibles y para detectar vapor de agua y/o humedad, dividido por categoría.

3.4 Métodos de IA y ML

En esta sección se analizan los métodos usados por temática. Se agruparon las investigaciones en tres categorías: 1) supervisadas, 2) no supervisadas y 3) una combinación de métodos no supervisados y supervisados. La figura 6 muestra la distribución de los métodos por categoría. Se calculó la proporción sobre el número total de métodos. En este cálculo se omitió el trabajo de [40] por ser considerados como un valor atípico del recuento, ya que los autores no utilizaron algoritmos de ML sino que se abocaron a realizar una revisión de todos los métodos conocidos para realizar InSAR (dentro de los cuales estudiaron algoritmos de ML).

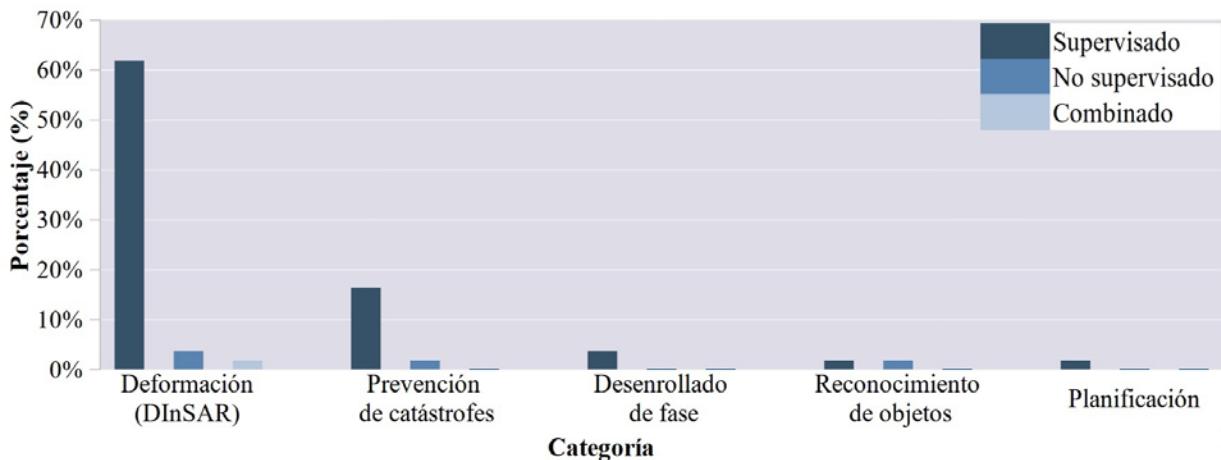


Figura 6. Distribución de los métodos de ML por categoría. El histograma muestra el porcentaje de artículos que utilizaron algoritmos supervisados, no supervisados o una combinación de ellos, por categoría.

En cuanto a los métodos de ML, se identificó una preeminencia de métodos supervisados, particularmente en estudios que utilizaron series temporales DInSAR para la predicción y detección de cambios en fenómenos geológicos, como deslizamientos de tierra, deformaciones del terreno y deformación volcánica. Esta tendencia se debe a que los métodos supervisados están diseñados para resolver tareas concretas y, para lograrlo, necesitan ejemplos etiquetados que les permitan aprender a reconocer patrones similares en nuevos datos. Los métodos no supervisados se aplicaron principalmente en temas de monitoreo mediante series temporales, ya sea de estructuras como puentes, fallas tectónicas o subsidencia. Esto se debe a que estos algoritmos tienen una mayor utilidad cuando se trabaja con grandes volúmenes de datos no clasificados. [62] y [68] utilizaron una combinación de métodos no supervisados y supervisados para la detección de deformación tectónica y volcánica.

Debido a su prominencia, se proporciona un análisis más detallado de los algoritmos empleados con mayor frecuencia para el aprendizaje supervisado y no supervisado. La figura 7 muestra la cantidad de veces que los documentos utilizaron algoritmos supervisados. A pesar de la amplia gama de algoritmos, los documentos tienden a utilizar principalmente unos pocos: las redes neuronales convolucionales (CNN), las redes neuronales de memoria a corto y largo plazo (LSTM), las máquinas de soporte vectorial (SVM), los bosque aleatorio (RF), los perceptrones de capas múltiples (MLP), las redes neuronales convolucionales profundas (D-CNN) y el aprendizaje profundo (DL). Con respecto a las LSTM, se debe tener en cuenta que estas son un tipo especializado de RNN diseñadas para abordar el problema de las dependencias a largo plazo. Introducidas por Hochreiter y Schmidhuber en 1997, las LSTM utilizan una estructura interna más compleja que le permite a la red aprender y recordar dependencias a largo plazo en los datos de entrada. Esto se logra a través de puertas de olvido, entrada y de salida que controlan el flujo de información dentro de la memoria de la red.

Los estudios que adoptaron solo algoritmos de aprendizaje no supervisado (figura 8) utilizaron principalmente auto-codificadores profundos (DCA) para la selección de datos y k-medias (k-means clustering) para fines de agrupación. También se usaron redes neuronales convoluciones no supervisadas (Canet). Además, se analizó la relación entre los temas y los métodos (tabla 1).

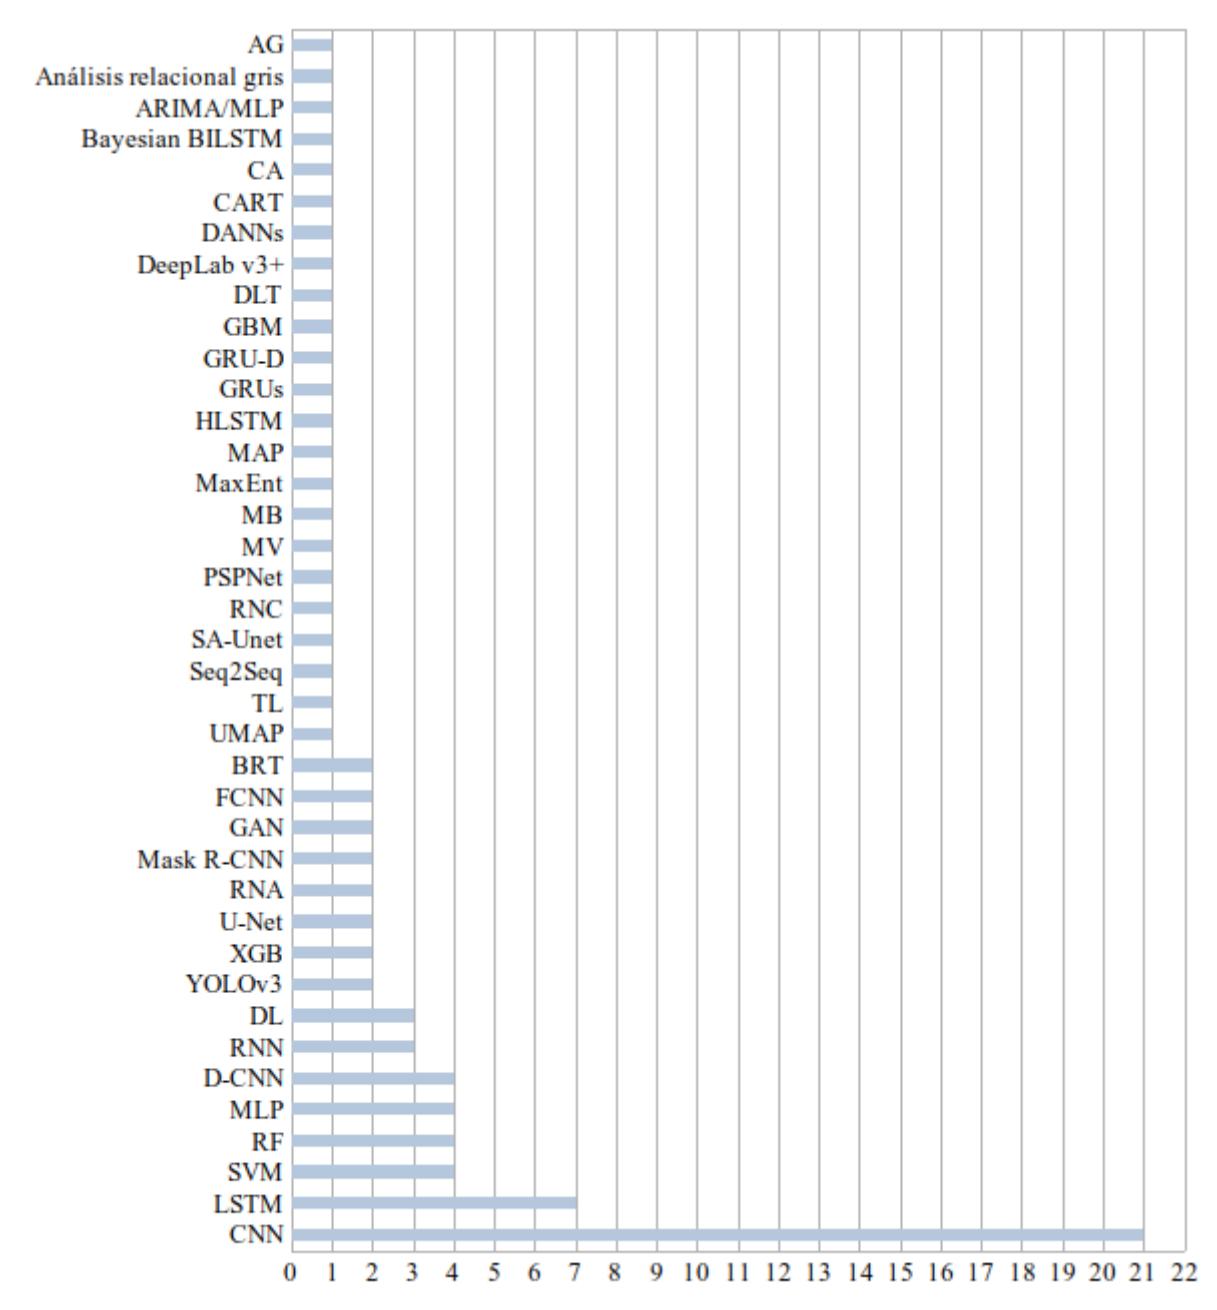


Figura 7. Histograma de las aplicaciones de los algoritmos de machine learning supervisados.

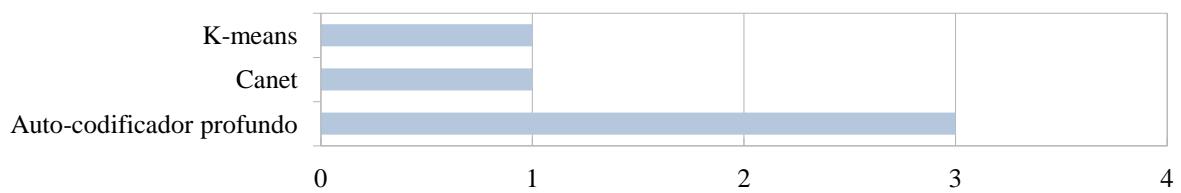


Figura 8. Histograma de las aplicaciones de los algoritmos de machine learning no supervisados.

Tabla 1. Algoritmos de ML usados en interferometría radar. Para cada tema, mostramos el algoritmo usado en el análisis. Se ha colocado entre paréntesis el número de publicaciones para algoritmos con más de una aplicación en el mismo tema. Si una publicación usa más de un método, se agrupan en el mismo tema. Abreviaciones: AG: algoritmos genéticos, BRT: árboles de regresión impulsados, CA: análisis de clúster, Cadet: redes neuronales no supervisadas, CART: árbol de clasificación y regresión, CNN: red neuronal convolucional, D-CNN: redes neuronales convolucionales profundas, DANNs: redes neuronales artificiales dinámicas, DL: aprendizaje profundo, DLT: transformadores en el aprendizaje profundo, FCNN: redes neuronales completamente conectadas, GAN: redes generativas adversariales, GBM: modelo de impulso generalizado, GRU: redes neuronales recurrentes bidireccionales con unidades recurrentes gateadas, LSTM: redes neuronales de memoria a corto y largo plazo, MAP: máxima a posteriori, Mask R-CNN: redes neuronales convolucionales basadas en regiones con máscaras, MaxEnt: máxima entropía, MB: enfoque basado en modelo, MLP: perceptrones de capas múltiples, MV: máxima verosimilitud, RF: Bosque aleatorio, RNA: redes neuronales artificiales, RNC: redes neuronales comutadas, RNN: red neuronal recurrente, SVM: máquinas de soporte vectorial, TL: aprendizaje de transferencia, UMAP: aproximación y proyección uniforme de variedades, XGB: refuerzo extremo de gradiente o XGBoost.

Tipo de método	Tema de estudio	Algoritmos
Supervisado	series temporales	MLP (2), RNA, AG, BRT (2), XGB (2), RNN (5), CNN (8), SLTM (2), MB, Mask R-CNN, D-CNN (2), Seq2Seq, GRU-D Auto-codificador convolucional, CART, RF (3), SVM (4), WOA, GWO, LSTM, DL, DANNs, GRU, DLT, ARIMA/MLP, 1D-CNN, BiLSTM
	interferometría de doble pasada	CNN (9), SVM, DL, GRU
	correcciones atmosféricas	CNN (2), RF, FCNN, MLP, SVM
	deslizamientos	U-Net, DeepLab v3+, PSPNet, YOLOv3, Mask R-CNN
	deformación volcánica	CNN (5), FCN, D-CNN, Canet
	deformación tectónica	RNA, AG, CNN (4), FCN, D-CNN, Canet
	prevención de catástrofes	RNN, auto-codificador convolucional, ANN, GBM, MaxEnt, U-Net, DeepLab v3+, PSPNet, CNN (5), SVM, GRU
	desenrollado de fase	GAN, MV, MAP, CA, CNN (2), SVM, DL, GRU
	reconocimiento de objetos	CNN, SVM, D-CNN
	planificación	CART, RF, SVM (2), BRT, CNN
No supervisado	series temporales	UMAP, LSTM, auto-codificador profundo
	interferometría de doble pasada	GAN
	correcciones atmosféricas	
	deslizamientos	
	deformación volcánica	
	deformación tectónica	K-means
	prevención de catástrofes	
	desenrollado de fase	CFAR, auto-codificador profundo
Combinado	series temporales	RNN, MLP
	interferometría de doble pasada	
	correcciones atmosféricas	
	deslizamientos	
	deformación volcánica	
	deformación tectónica	
	prevención de catástrofes	
	desenrollado de fase	
	reconocimiento de objetos	
	planificación	

3.5 Patrones en la selección de parámetros

En esta sección, se analizaron patrones en la selección de los parámetros, tanto en ML supervisado como no supervisado. En el aprendizaje supervisado, se investigó la información reportada sobre el entrenamiento y las pruebas. Aunque la elección de los parámetros tiene un impacto importante en los resultados, se encontró que a menudo los autores no detallan adecuadamente el proceso de selección de parámetros de entrenamiento y de prueba. De los que sí lo hicieron, la mayoría dividió los datos en dos conjuntos: el conjunto de datos de entrenamiento (que comprendía generalmente entre el 70% y el 80% de los datos), y el conjunto de datos para las pruebas (entre el 20% y el 30% del total de los datos). Algunas de las publicaciones en las que se realizaron análisis temporales optaron por dividir los datos de entrenamiento y pruebas por año (por ejemplo [1] y [29]). Otros autores utilizaron tres conjuntos de datos: uno para la capacitación, otro para la validación y otro para las pruebas [20], [32] y [50]. Pocos artículos informaron sistemáticamente sobre la selección de los hiperparámetros, y hasta el momento no existe un estándar común. Por ejemplo, ningún autor usó viñetas para enumerar los hiperparámetros de los diferentes

algoritmos. [5], [10], [25], [36], [39], [41] y [64] emplearon tablas para informar sobre los hiperparámetros y sobre la arquitectura de NN. Sin embargo, la gran mayoría de los artículos no lo hicieron ni dieron detalles sobre la arquitectura del modelo. Aquellos autores que sí especificaron los hiperparámetros, lo hicieron principalmente en el cuerpo del texto en lugar de hacerlo en un forma detallada y sistemática a través de tablas o figuras, lo que dificulta la lectura de la información. Este hallazgo estaba en línea con críticas anteriores sobre la falta de información clara de los hiperparámetros en redes neuronales artificiales [31].

Con respecto a los trabajos que emplearon ML no supervisado, se analizó cómo se desarrollaron tanto la agrupación como el análisis de componentes principales (PCA). Para los algoritmos de agrupamiento, se distinguieron dos enfoques: (i) determinar el número óptimo de conglomerados mediante el uso de algoritmos sistemáticos, (ii) determinar manualmente el número de conglomerados y luego que el algoritmo asigne los datos a cada conglomerado. Dentro de la primera categoría (i), [25] y [68] seleccionaron el número óptimo de grupos utilizando el coeficiente de partición y la entropía de clasificación. Varios autores, [14], [64] y [65], emplearon clusterogramas para identificar grupos de k-medias. Este método consiste en trazar una serie de valores potenciales de k . En estos casos, el número óptimo de grupos de k-medias se evaluó utilizando el coeficiente de silueta desarrollado por [63]. En la segunda categoría (ii), [68] seleccionó el número de grupos basándose en evaluaciones empíricas de los casos de estudio.

En relación con el análisis de componentes principales (PCA), esta técnica fue utilizada para facilitar la interpretación de los datos y optimizar el rendimiento de los modelos. Los estudios [14], [64] y [65] aplicaron el PCA como paso previo al agrupamiento, permitiendo identificar las variables que explicaban la mayor parte de la varianza en los conjuntos de datos. En todos estos casos, se utilizó el criterio de Kaiser, que es una regla empírica que ayuda a decidir cuántos componentes retener.

Este análisis pone de manifiesto la necesidad de avanzar hacia criterios más sistemáticos y claramente documentados en la selección de parámetros en modelos ML aplicados a InSAR, lo cual resultaría clave para mejorar la reproducibilidad de los experimentos y facilitar comparaciones entre estudios.

4 Conclusiones

En este trabajo se propuso revisar el estado del arte de la IG aplicada a la InSAR. Como este es un campo del saber emergente y en rápido desarrollo, se llevó a cabo una revisión exploratoria para (i) mapear los temas más destacados, fuentes de datos, algoritmos de aprendizaje automático y enfoques para la selección de parámetros, (ii) determinar los desafíos en la aplicación del aprendizaje automático en InSAR, (iii) identificar vacíos de conocimiento para orientar a las futuras investigaciones. Se revisaron trabajos que abarcan diferentes algoritmos de ML en todos los aspectos de los procesamientos interferométricos, divididos en las categorías de métodos supervisados y no supervisados. El análisis de los documentos permitió crear una clasificación de enfoques de aprendizaje automático según temas, métodos y fuentes de datos.

Se destacan tres conclusiones principales de este estudio. En primer lugar, mencionar que todavía hay amplias oportunidades para evolucionar en este campo del saber, investigando temas faltantes o trabajando en estudios de casos interdisciplinarios o comparativos. A medida que el aprendizaje automático y la IA se hacen más populares, sus aplicaciones permitirán resolver problemas en cuestiones relacionadas con las ciencias de la Tierra, como la prevención de catástrofes y la mitigación de daños. Segundo, aún existe la necesidad de estandarizar la selección de datos, algoritmos y parámetros, ya que las comparaciones sistemáticas de la selección de datos y algoritmos pueden ayudar a explorar la importancia de estos métodos y los impactos de los resultados, aumentando la reproducibilidad y transparencia de los trabajos. Tercero, el aprendizaje automático espacial se beneficiará de una integración de los distintos tipos de datos, permitiendo procesos de análisis más significativos.

Mediante este trabajo, se pretende que la comunidad científica pueda utilizar esta revisión como una guía para comprender qué enfoques y conjuntos de datos se han utilizado para abordar qué tipos de problemas, y que el análisis presentado ayude a comprender de manera integral el uso de la IG aplicada a los datos geoespaciales. También, se identificaron algunas áreas prometedoras para incursionar en investigaciones futuras, desde la necesidad de más estudios comparativos hasta una mejor comprensión del impacto de la selección de conjuntos de datos, algoritmos o parámetros. En este estudio, se hizo hincapié en la necesidad de fomentar enfoques de aprendizaje automático más fácilmente explicables e invertir en la transferencia de conocimientos para ayudar a difundir estas herramientas que

mejoran la calidad de los análisis espaciales, a fin de permitirle a los equipos de investigadores abordar mejor los numerosos desafíos a los que se enfrentan.

Los resultados de este trabajo subrayan que, si bien los modelos supervisados han sido ampliamente utilizados, los modelos híbridos emergen como una solución prometedora que combina lo mejor de ambos enfoques para mejorar la precisión en la detección de deformaciones en InSAR. Nuestro análisis revela que la integración de aprendizaje automático con técnicas InSAR no solo incrementa la precisión de las detecciones, sino que también abre nuevas oportunidades para el monitoreo geoespacial en regiones con escasez de datos clasificados. Se recomienda explorar más a fondo el uso de estos modelos híbridos y auto-supervisados, así como el desarrollo de criterios estandarizados para evaluar la efectividad de estos enfoques. Esto podría allanar el camino hacia mejores aplicaciones de la inteligencia geoespacial.

Referencias

- [1] AK Agrawal, H. Verma y S. Pasari. InSAR data analysis using deep neural networks. *IOP Conference Series: Earth and Environmental Science*, 1032(1):012025, 2022. <https://doi.org/10.1088/1755-1315/1032/1/012025>.
- [2] R. Amin, E. Rojas, A. Aqdus, S. Ramzan, D. Casillas-Pérez y J. M. Arco. A survey on machine learning techniques for routing optimization in SDN. *IEEE Access*, 9:104582–104611, 2021. <https://doi.org/10.1109/access.2021.3099092>.
- [3] N. Anantrasirichai, J. Biggs, F. Albino, P. Hill y D. Bull. Application of machine learning to classification of volcanic deformation in routinely generated InSAR data. *Journal of Geophysical Research: Solid Earth*, 123(8):6592–6606, 2018. <https://doi.org/10.1029/2018jb015911>.
- [4] N. Anantrasirichai, F. Albino, P. Hill, D. Bull y J. Biggs. Detecting volcano deformation in InSAR using deep learning. *arXiv* (Cornell University), 2018. <https://arxiv.org/pdf/1803.00380.pdf>.
- [5] N. Anantrasirichai, J. Biggs, F. Albino y D. Bull. A deep learning approach to detecting volcano deformation from satellite imagery using synthetic datasets. *Remote Sensing of Environment*, 230:111179, 2019. <https://doi.org/10.1016/j.rse.2019.04.032>.
- [6] N. Anantrasirichai, J. Biggs, F. Albino y D. Bull. The application of convolutional neural networks to detect slow, sustained deformation in InSAR time series. *Geophysical Research Letters*, 46(21):11850–11858, 2019. <https://doi.org/10.1029/2019gl084993>.
- [7] N. Anantrasirichai, J. Biggs, K. Kelevitz, Z. Sadeghi, T. Wright, J. F. Thompson, A. Achim y D. Bull. Detecting ground deformation in the built environment using sparse satellite InSAR data with a convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 59(4):2940–2950, 2021. <https://doi.org/10.1109/tgrs.2020.3018315>.
- [8] H. Ansari, M. RuBwurm, M. Ali, S. Montazeri, A. Parizzi y X. X. Zhu. InSAR displacement time series mining: A machine learning approach. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 2021. <https://doi.org/10.1109/igarss47720.2021.9553465>.
- [9] N. Ashrafianfar y M. Mohammad Rezapour Tabari. DInSAR time series as inverse solution of Artificial Intelligence Machine Learning Approaches for spatio-temporal simulation of land subsidence. [Published Resume], 2020. <https://doi.org/10.13140/RG.2.2.30381.72165>.
- [10] C. Baumann, M. Kiani Shahvandi, A. Duckstein, M. Westerhaus y B. Soja. Using machine learning to predict earth deformation from InSAR time series. *Publikationen Der Deutschen Gesellschaft Für Photogrammetrie Fernerkundung Und Geoinformation*, 31, 2023. <https://doi.org/10.3929/ethz-b-000607625>.
- [11] J. Biggs, N. Anantrasirichai, F. Albino, M. Lázecký y Y. Maghsoudi. Large-scale demonstration of machine learning for the detection of volcanic deformation in Sentinel-1 satellite imagery. *Bulletin of Volcanology*, 84(12), 2022. <https://doi.org/10.1007/s00445-022-01608-x>.
- [12] C. Bignami, A. Antonioli, S. Atzori, A. Kiratzi, M. Polcari, N. Savigas, C. Tolomei y GEOSAR laboratory. Mapping InSAR deformation of low and moderate earthquakes. *Procedia Computer Science*, 181:214-219, 2021. <https://doi.org/10.1016/j.procs.2021.01.139>.

- [13] A. Bralet, E. Trouvé, J. Chanussot y A. M. Atto. ISSLIDE: A new InSAR dataset for Slow Sliding area DEtection with machine learning. *IEEE Geoscience and Remote Sensing Letters*, 1, 2024. <https://doi.org/10.1109/lgrs.2024.3365299>.
- [14] G. Brencher, S. Henderson y D. Shean. Removing atmospheric noise from InSAR interferograms in mountainous regions with a convolutional neural network. *EGU General Assembly Conference Abstracts*, 2023. <https://doi.org/10.36227/techriv.22626748>.
- [15] C. Brengman y W. D. Barnhart. Identification of surface deformation in InSAR using machine learning. *Geochemistry Geophysics Geosystems*, 22(3):2021, 2021. <https://doi.org/10.1029/2020gc009204>.
- [16] C. Brengman. Next generation analysis of earthquakes and earthquake catalogs with InSAR, 2021. <https://doi.org/10.17077/etd.006012>.
- [17] Y. Casali, N. Y. Aydin y T. Comes. Machine learning for spatial analyses en urban areas: a scoping review. *Sustainable Cities and Society*, 85:104050, 2022. <https://doi.org/10.1016/j.scs.2022.104050>.
- [18] C. Chen, K. Dai, X. Tang, J. Cheng, S. Pirasteh, M. Wu, X. Shi, H. Zhang y Z. Li. Removing InSAR topography-dependent atmospheric effect based on deep learning. *Remote Sensing*, 14(17):4171, 2022. <https://doi.org/10.3390/rs14174171>.
- [19] C. Colesanti y J. Wasowski. Investigating landslides with space-borne synthetic aperture radar (SAR) interferometry. *Engineering Geology*, 88(3–4):173–199, 2006. <https://doi.org/10.1016/j.enggeo.2006.09.013>.
- [20] P. Conroy, S. A. N. Van Diepen, S. Van AsseLEN, G. Erkens, F. Van Leijen y R. F. Hanssen. Probabilistic estimation of InSAR displacement phase guided by contextual information and artificial intelligence. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–11, 2022. <https://doi.org/10.1109/tgrs.2022.3203872>.
- [21] M. Crosetto, O. Monserrat, M. Cuevas-González, N. Devanthéry y B. Crippa. Persistent scatterer interferometry: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115:78–89, 2016. <https://doi.org/10.1016/j.isprsjprs.2015.10.011>.
- [22] P. Euillades, L. Euillades, M. Blanco, G. Cabrera, J. Witte y J. Bergamasco. Aplicación de modelos digitales de elevación basados en imágenes SAR en el estudio de la geología estructural. *Petrotecnia. Instituto Argentino del Petróleo y el Gas*, 58–68, 2005. <https://bicyt.conicet.gov.ar/fichas/produccion/5844882>.
- [23] P. Euillades, M. Blanco y L. Euillades. Caracterización de fenómenos deformativos mediante imágenes de radar: potenciales aplicaciones en el campo petrolero. *VII Congreso de Exploración y Desarrollo de Hidrocarburos*, Mar del Plata, Argentina, 2008.
- [24] P. A. Euillades, N. C. Riveros, M. H. Masiokas, L. E. Ruiz, P. M. Pitte, S. Elefante, F. Casu y S. Balbarani. Detection of glaciers displacement time-series using SAR. *Remote Sensing of Environment*, 184:188–198, 2016. <https://doi.org/10.1016/j.rse.2016.07.003>.
- [25] M. F. Fadhillah, W. L. Hakim, S. Park, D. W. Kim, Y. Park, C. Kim y C. Lee. Surface deformation simulation for InSAR detection using a machine learning approach on the Hantangang river volcanic field: A case study on the Orisan mountain. *Frontiers in Environmental Science*, 10, 2022. <https://doi.org/10.3389/fenvs.2022.968120>.
- [26] A. Ferretti, A. Monti-Guarnieri, C. Prati, F. Rocca y D. Massonnet. InSAR principles - guidelines for SAR interferometry processing and interpretation. *ESA Training Manual*, 19, 2007.
- [27] N. Fiorentini, M. Maboudi, P. Leandri y M. Losa. Can machine learning and PS-InSAR reliably stand in for road profilometric surveys? *Sensors*, 21(10):3377, 2021. <https://doi.org/10.3390/s21103377>.
- [28] M. Gaddes, A. Hooper y F. Albino. Simultaneous classification and location of volcanic deformation in SAR interferograms using a convolutional neural network. *EarthArXiv* (California Digital Library), 2023. <https://doi.org/10.31223/x5cw2j>.
- [29] V. Gagliardi, F. Tosti, L. B. Ciampoli, F. D'Amico, A. M. Alani, M. L. Battagliere y A. Benedetto. Monitoring of bridges by MT-InSAR and unsupervised machine learning clustering techniques. [Conference presentation]. *Earth Resources and Environmental Remote Sensing/GIS Applications XII*, 2021. <https://doi.org/10.1117/12.2597509>.

- [30] R. Y. Gens y J. L. Van Genderen. SAR Interferometry - Issues, techniques, applications. *International Journal of Remote Sensing*, 17:1803–1835, 1996.
- [31] G. Grekousis, G. Mountrakis y M. Kavouras. An overview of artificial neural networks in mapping land cover and land use. *International Journal of Remote Sensing*, 40(17):6262–6296, 2019.
- [32] S. Haji-Aghajany, M. Pirooznia, M. R. Naeeni y Y. Amerian. Combination of Artificial Neural Network and Genetic Algorithm to Inverse Source Parameters of Sefid-Sang Earthquake Using InSAR Technique and Analytical Model Conjunction. *Journal of the Earth and Space Physics*, 45(4):121–131, 2020. <https://doi.org/10.22059/jesphys.2019.269596.1007065>.
- [33] R. Hanssen. Radar interferometry: data interpretation and error analysis. *Journal of Computer and Communications*, 2001. <https://doi.org/10.1007/0-306-47633-9>.
- [34] Y. He, G. Zhang, H. Kaufmann y G. Xu. Automatic interferogram selection for SBAS-InSAR based on deep convolutional neural networks. *Remote Sensing*, 13(21):4468, 2021. <https://doi.org/10.3390/rs13214468>.
- [35] Y. Hu, Y. Li y Z. Pan. A dual-polarimetric SAR ship detection dataset and a memory-augmented autoencoder-based detection method. *Sensors*, 21(24):8478, 2021. <https://doi.org/10.3390/s21248478>.
- [36] R. S. Kuzu, Y. Wang, O. Dumitru, L. Bagaglini, G. Pasquali, F. Santarelli, F. Trillo, S. Saha y X. X. Zhu. An unsupervised anomaly detection problem in urban InSAR-PSP long time-series. *EGU General Assembly Conference Abstracts*, 2023. <https://doi.org/10.5194/egusphere-egu23-13106>.
- [37] R. Lanari, P. Lundgren, M. Manzo y F. Casu. Satellite radar interferometry time series analysis of surface deformation for Los Angeles, California. *Geophysical Research Letters*, 31, 2004. <https://doi.org/10.1029/2004GL021294>.
- [38] R. Lanari, F. Casu, M. Manzo, G. Zeni, P. Berardino, M. Manunta y A. Pepe. An overview of the Small Baseline Subset algorithm: a DInSAR technique for surface deformation analysis. *Pure and Applied Geophysics*, 164:637–661, 2007. <https://doi.org/10.1007/s00024-007-0192-9>.
- [39] F. Lattari, A. Rucci y M. Matteucci. A deep learning approach for change points detection in InSAR time series. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–16, 2022. <https://doi.org/10.1109/tgrs.2022.3155969>.
- [40] S. Li, W. Xu y Z. Li. Review of the SBAS InSAR time-series algorithms, applications, and challenges. *Geodesy and Geodynamics*, 13(2):114–126, 2022. <https://doi.org/10.1016/j.geog.2021.09.007>.
- [41] Y. Liu, X. Yao, Z. Gu, Z. Zhou, X. Liu, X. Chen y S. Wei. Study of the automatic recognition of landslides by using InSAR images and the improved Mask R-CNN model in the eastern Tibet Plateau. *Remote Sensing*, 14(14):3362, 2022. <https://doi.org/10.3390/rs14143362>.
- [42] F. Lv, Q. Zhang, T. Wang, W. Li, F. Liu y D. Ge. Detecting slow-moving landslides using InSAR phase-gradient stacking and deep-learning network. *Frontiers in Environmental Science*, 10, 2022. <https://doi.org/10.3389/fenvs.2022.963322>.
- [43] P. Ma, F. Zhang y H. Lin. Prediction of InSAR time-series deformation using deep convolutional neural networks. *Remote Sensing Letters*, 11(2):137–145, 2019. <https://doi.org/10.1080/2150704X.2019.1692390>.
- [44] D. Massonnet, M. Rossi, C. Carmona, F. Adragna, G. Peltzer, K. Feigl y T. Rabaute. The displacement field of the Landers earthquake mapped by radar interferometry. *Nature*, 364(6433):138–142, 1993. <https://doi.org/10.1038/364138a0>.
- [45] D. Massonnet y K. L. Feigl. Radar interferometry and its application to changes in the earth's surface. *Reviews of Geophysics*, 36(4):441–500, 1998. <https://doi.org/10.1029/97RG03139>.
- [46] S. M. Mirmazloumi, Á. F. Gambín, R. Palamà, M. Crosetto, Y. Wassie, J. A. Navarro, A. Barra y O. Monserrat. Supervised machine learning algorithms for ground motion time series classification from InSAR data. *Remote Sensing*, 14(15):3821, 2022. <https://doi.org/10.3390/rs14153821>.

- [47] S. M. Mirmazloumi, Á. F. Gambín, Y. Wassie, A. Barra, R. Palamà, M. Crosetto, O. Monserrat y B. Crippa. InSAR deformation time series classification using a convolutional neural network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2022:307–312, 2022. <https://doi.org/10.5194/isprs-archives-xliii-b3-2022-307-2022>.
- [48] B. Moseley y L. Krischer. Machine learning and artificial intelligence in geosciences (1st ed., Vol. 61). Academic Press, 2020.
- [49] Z. Munn, M. D. J. Peters, C. Stern, C. Tufanaru, A. McArthur y E. Aromataris. Systematic review or scoping review? Guidance for authors when choosing between a systematic or scoping review approach. *BMC Medical Research Methodology*, 18:Article 143, 2018. <https://doi.org/10.1186/s12874-018-0611-x>.
- [50] S. A. Naghibi, H. Hashemi y B. Khodaei. An integrated InSAR-machine learning approach for ground deformation rate modeling in arid areas. *Journal of Hydrology*, 608:127627, 2022. <https://doi.org/10.1016/j.jhydrol.2022.127627>.
- [51] L. Nava, E. Carraro, C. Reyes-Carmona, S. Puliero, K. Bhuyan, A. Rosi, O. Monserrat, M. Floris, S. R. Meena, J. P. Galvé y F. Catani. Landslide displacement forecasting using deep learning and monitoring data across selected sites. *Landslides*, 20(10):2111–2129, 2023. <https://doi.org/10.1007/s10346-023-02104-9>.
- [52] A. Novellino, M. Cesarano, P. Cappelletti, D. Di Martire, M. Di Napoli, M. Ramondini, A. Sowter y D. Calcaterra. Slow-moving landslide risk assessment combining machine learning and InSAR techniques. *CATENA*, 203:105317, 2021. <https://doi.org/10.1016/j.catena.2021.105317>.
- [53] D. Orlandi, F. A. Galatolo, M. G. C. A. Cimino, A. La Rosa, C. Pagli y N. Perilli. Enhancing land subsidence awareness via InSAR data and deep transformers. *IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 2022. <https://doi.org/10.1109/cogsima54611.2022.9830661>.
- [54] M. D. J. Peters, C. M. Godfrey, H. Khalil, P. McInerney, D. Parker y C. B. Soares. Guidance for conducting systematic scoping reviews. *International Journal of Evidence-Based Healthcare*, 13(3):141–146, 2015. <https://doi.org/10.1097/XEB.0000000000000050>.
- [55] Proceedings of the 6th China High Resolution Earth Observation Conference (CHREOC 2019). In *Lecture Notes in Electrical Engineering*, 2020. <https://doi.org/10.1007/978-981-15-3947-3>.
- [56] A. Radman, M. Akhoondzadeh y B. Hosseiny. Integrating InSAR and deep learning for modeling and predicting subsidence over the adjacent area of Lake Urmia, Iran. *Giscience & Remote Sensing*, 58(8):1413–1433, 2022. <https://doi.org/10.1080/15481603.2021.1991689>.
- [57] J. Raventós y C. Sánchez. The use of InSAR for monitoring slope stability of rock masses. *ISRM 1st International Conference on Advances in Rock Mechanics – TuniRock 2018*, Hammamet, Tunisia, marzo 2018. <https://onepetro.org/ISRM-TUNIROCK/proceedings/TUNIROCK18/All-TUNIROCK18/ISRM-TUNIROCK-2018-06/42263>.
- [58] G. Rongier, C. Rude, T. A. Herring y V. Pankratius. An attempt at improving atmospheric corrections in InSAR using cycle-consistent adversarial networks. *EarthArXiv* (California Digital Library), 2020. <https://doi.org/10.31223/x5m594>.
- [59] B. Rouet-Leduc, M. Dalaison, P. A. Johnson y R. Jolivet. Deep learning InSAR: atmospheric noise removal and small deformation signal extraction from InSAR time series using a convolutional autoencoder. *AGU Fall Meeting Abstracts*, 2019. <https://ui.adsabs.harvard.edu/abs/2019AGUFM.G21A..07R/abstract>.
- [60] B. Rouet-Leduc, R. Jolivet, M. Dalaison, P. A. Johnson y C. Hulbert. Autonomous extraction of millimeter-scale deformation in InSAR time series using deep learning. *Nature Communications*, 12(1), 2021. <https://doi.org/10.1038/s41467-021-26254-3>.
- [61] P. Rusia, Y. Bhateja, I. Misra, S. M. Moorthi y D. Dhar. An efficient machine learning approach for atmospheric correction. *Journal of the Indian Society of Remote Sensing*, 49(10):2539–2548, 2021. <https://doi.org/10.1007/s12524-021-01406-6>.

- [62] A. Shakeel, R. J. Walters, S. K. Ebmeier y N. A. Moubayed. Detection of tectonic and volcanic deformation as anomalies in InSAR: deep-learning tailored to differential data. [Preprint], 2022. <https://doi.org/10.1002/essoar.10512903.1>.
- [63] Y. Shi y Y. Zheng. Automatic method for determining cluster number based on silhouette coefficient. *Advanced Materials Research*, 951:227–230, 2014. <https://doi.org/10.4028/www.scientific.net/AMR.951.227>.
- [64] F. Sica, G. Gobbi, P. Rizzoli y L. Bruzzone. Φ-Net: Deep Residual Learning for InSAR Parameters Estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5):3917–3941, 2021. <https://doi.org/10.1109/tgrs.2020.3020427>.
- [65] O. M. Sorkhabi, A. S. Nejad y M. Khajehzadeh. Evaluation of Isfahan City subsidence rate using InSAR and artificial intelligence. *KSCE Journal of Civil Engineering*, 26(6):2901–2908, 2022. <https://doi.org/10.1007/s12205-022-2013-1>.
- [66] O. L. Stephenson, T. Köhne, E. Zhan, B. E. Cahill, S. Yun, Z. E. Ross y M. Simons. Deep learning-based damage mapping with InSAR coherence time series. *IEEE Transactions on Geoscience and Remote Sensing*, 60:1–17, 2022. <https://doi.org/10.1109/tgrs.2021.3084209>.
- [67] X. Sun, A. Zimmer, S. Mukherjee, N. K. Kottayil, P. Ghuman y I. Cheng. DeepINSAR—A deep learning framework for SAR interferometric phase restoration and coherence estimation. *Remote Sensing*, 12(14):2340, 2020. <https://doi.org/10.3390/rs12142340>.
- [68] A. Tiwari y M. Shirzaei. A novel machine learning and deep learning semi-supervised approach for automatic detection of InSAR-based deformation hotspots. *International Journal of Applied Earth Observation and Geoinformation*, 126:103611, 2024. <https://doi.org/10.1016/j.jag.2023.103611>.
- [69] X. Tong, D. T. Sandwell y Y. Fialko. Coseismic slip model of the 2008 Wenchuan earthquake derived from joint inversion of interferometric synthetic aperture radar, GPS, and field data. *Journal of Geophysical Research: Solid Earth*, 115(B4), 2010. <https://doi.org/10.1029/2009JB006625>.
- [70] Z. Wu, H. Zhang, Y. Wang, T. Wang y R. Wang. A deep learning based method for local subsidence detection and InSAR phase unwrapping: application to mining deformation monitoring. *2020 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2020)*, 2020. <https://doi.org/10.1109/igarss39084.2020.9323342>.
- [71] S. Valade, A. Ley, F. Massimetti, O. D'Hondt, M. Laiolo, D. Coppola, D. Loibl, O. Hellwich y T. R. Walter. Towards global volcano monitoring using multisensor Sentinel missions and artificial intelligence: The MOUNTS monitoring system. *Remote Sensing*, 11(13):1528, 2019. <https://doi.org/10.3390/rs11131528>.
- [72] L. F. Velasquez, M. Etxegarai, L. Echeverria y G. A. Varas. Detección automática de árboles urbanos a partir de imágenes de Google Street View. *VIII Congreso Forestal Español*, 2022.
- [73] M. Velez, P. Euillardes, M. Blanco y L. Euillardes. Ground deformation between 2002 and 2013 from InSAR observations. *Copahue Volcano*, 175–198, 2016. https://doi.org/10.1007/978-3-662-48005-2_8.
- [74] Y. Wang, Z. Ou, J. Zhu, X. Dong, X. Xing y Y. Yang. Coseismic deformation of 2009 L'Aquila, Italy earthquake derived from ascending and descending ENVISAT/ASAR images. *2020 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2020)*, 2020. <https://doi.org/10.1109/WICOM.2010.5601041>.
- [75] T. Wang, Q. Zhang y Z. Wu. A deep-learning-facilitated, detection-first strategy for operationally monitoring localized deformation with large-scale InSAR. *Remote Sensing*, 15(9):2310, 2023. <https://doi.org/10.3390/rs15092310>.
- [76] Q. Wu, D. Ge, J. Y. Junchuan, L. Zhang, M. Li, B. Liu, Y. Wang, Y. Ma y L. H. Liu. Deep learning identification technology of InSAR significant deformation zone of potential landslide hazard at large scale. *DOAJ (Directory of Open Access Journals)*, 2022. <https://doi.org/10.11947/j.agcs.2022.20220303>.
- [77] S. Yang, Y. Wang, P. Wang, J. Mu, S. Jiao, X. Zhao, Z. Wang, K. Wang y Y. Zhu. Automatic identification of landslides based on deep learning. *Applied Sciences*, 12(16):8153, 2022. <https://doi.org/10.3390/app12168153>.

- [78] J. Yazbeck y J. B. Rundle. A data-driven approach to deformation forecasting: Machine learning on InSAR data. *Authorea*, 2023. <https://doi.org/10.22541/essoar.170365217.79116412/v1>.
- [79] Y. L. M. Yilu y L. Yuehua. Millimeter-wave InSAR target recognition with deep convolutional neural network. *IEICE Trans. Inf. & Syst.*, E102-D, No.3, 2019. https://www.jstage.jst.go.jp/article/transinf/E102.D/3/E102.D_2018EDL8158/_pdf.
- [80] N. H. K. Yue. Tropospheric correction for InSAR using machine learning. [Master's dissertation, Missouri University of Science and Technology], 2023. https://scholarsmine.mst.edu/cgi/viewcontent.cgi?article=9158&context=masters_theses.
- [81] Y. G. Yuh, W. Tracz, H. D. Matthews y S. Turner. Application of machine learning approaches for land cover monitoring in northern Cameroon. *Ecological Informatics*, 74:101955, 2023. <https://doi.org/10.1016/j.ecoinf.2022.101955>.
- [82] Z. Zhao. Exploring the application of deep learning methods for InSAR time-series analysis. [PhD Thesis], 2021. <https://repository.lib.cuhk.edu.hk/en/item/cuhk-2876319?solr.nav%5Bid%5D=38de08630ba9da249da9&solr.nav%5Bpage%5D=0&solr.nav%5Boffset%5D=0>.
- [83] Z. Zhao, Z. Wu, Y. Zheng y P. Ma. Recurrent neural networks for atmospheric noise removal from InSAR time series with missing values. *ISPRS Journal of Photogrammetry and Remote Sensing*, 180:227–237, 2021. <https://doi.org/10.1016/j.isprsjprs.2021.08.009>.
- [84] L. Zhou, H. Yu, Y. Lan y M. Xing. Artificial intelligence in interferometric synthetic aperture radar phase unwrapping: A review. *IEEE Geoscience and Remote Sensing Magazine*, 9(2):10–28, 2021. <https://doi.org/10.1109/mgrs.2021.3065811>.