



**2025** | **16-20**  
**GIJÓN** | **JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1315**

Actas del Noveno Congreso Forestal Español  
Edita: **Sociedad Española de Ciencias Forestales. 2025.**  
ISBN: **978-84-941695-7-1**

Organiza





## Delimitación de cicatriz de incendio forestal mediante combinación de productos SAR e InSAR de banda L y C: Caso de estudio incendio forestal Las Máquinas, Chile

MIGUEL AGUILERA-PERALTA, M. (1), GUTIÉRREZ-CÁCERES, F. (2), CABRERA-ARIZA, A. (1)(3), SANTELICES-MOYA, R. (1)

(1) Centro del Secano, Facultad de Ciencias Agrarias y Forestales, Universidad Católica del Maule, Talca, Chile.

(2) Centro de Modelamiento Matemático, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, Santiago, Chile.

(3) Centro de Investigaciones de Estudios Avanzados del Maule, Vicerrectoría de Investigación y Postgrado, Universidad Católica del Maule, Talca, Chile.

### Resumen

La detección y delimitación precisa de incendios forestales (IF) es un desafío significativo en condiciones atmosféricas adversas, como la presencia de nubes o humo. Los sensores satelitales activos, como el radar de apertura sintética (SAR), han demostrado ser efectivos en estas situaciones. Este estudio aborda el IF “Las Máquinas” en la región del Maule (Chile), ocurrido en el verano de 2017, que afectó aproximadamente 160,000 ha. según lo identificado por la Corporación Nacional Forestal de Chile (CONAF), siendo este un evento de gran magnitud sin precedentes a escala global. Utilizando imágenes SAR de ALOS-2 (banda L, modo Dsc) y Sentinel-1 (banda C, modo Dsc), procesadas con el software AMSTer Software, para determinar la superficie afectada (SA) del incendio bajo condiciones de nubosidad y humo. Mediante QGIS, se generó una composición de Intensidad-Coherencia y una clasificación supervisada para delimitar cartográficamente la SA. Los resultados indicaron que la polarización HH de ALOS-2 estimó una SA de 116,066 ha, siendo la más precisa (0,94%). Se concluye que la longitud de onda más larga de la banda L en comparación con la banda C mejora la interacción con la superficie y la retrodispersión (especialmente en HV y HH), facilitando una delimitación más precisa del área afectada por el IF, incluso bajo condiciones de humo o nubes.

### Palabras clave

InSAR, coherencia, intensidad, incendio, precisión

#### 1. Introducción

La Observación de la Tierra mediante datos satelitales representa una herramienta esencial para el monitoreo y análisis de fenómenos naturales y antrópicos, gracias a su capacidad para capturar información reflejada o emitida desde la superficie terrestre en distintas regiones del espectro electromagnético (CAMPBELL & WYNNE, 2011). Entre estas tecnologías, los sensores satelitales, tanto pasivos como activos, han revolucionado la manera de estudiar y gestionar los recursos naturales. Mientras que los sensores pasivos dependen de la energía solar para medir la radiación reflejada, los sensores activos, como los de microondas, emiten su propia energía, garantizando observaciones continuas bajo cualquier



condición atmosférica y durante las 24 horas del día (LAVANDER & LAVANDER, 2015)(KIM, 2013). Estas características hacen que los sistemas de Radar de Apertura Sintética (SAR) sean especialmente valiosos en aplicaciones que requieren una cobertura temporal y espacial constante, incluso en escenarios de alta complejidad ambiental.

La tecnología SAR ha demostrado su versatilidad en diversas áreas de investigación, como silvicultura, agricultura, hidrología, urbanismo y monitoreo de infraestructura, permitiendo obtener datos precisos sobre variables biogeofísicas (KUMAR et al., 2022). En particular, su aplicación en el estudio de incendios forestales ha ganado relevancia debido a la capacidad de estos sistemas para registrar cambios en la retrodispersión antes, durante y después de los eventos de fuego (HOEKMAN, 2001; DAGESTAD et al., 2012; DERAUW et al., 2020; TANASE et al., 2010). Estos cambios están relacionados con las propiedades de humedad del suelo, la biomasa y las condiciones de la vegetación, lo que permite identificar áreas afectadas y evaluar la severidad del daño. Además, la combinación de diferentes bandas de frecuencia y polarizaciones ha demostrado ser efectiva para discriminar entre tipos de combustibles, detectar focos activos y analizar la recuperación post-incendio (KURUM, 2015; BERNHARD et al., 2011; ALARCON-AGUIRRE, 2022).

Una de las herramientas más utilizadas en el análisis de datos SAR es la composición RGB, que permite representar visualmente diferentes variables o momentos temporales mediante los canales Rojo, Verde y Azul (PATRA et al., 2006). Esta técnica ha sido ampliamente empleada en la detección de cambios, combinando datos de coherencia e intensidad (AMITRANO et al., 2016; NAS et al., 2021) o utilizando información de retrodispersión obtenida en diferentes fechas (BONDUR et al., 2023; MAFAZ & WELIKANNA, 2016; CIGNA et al., 2013). Los sistemas SAR registran tanto la amplitud como la fase de los ecos retrodispersados (LWIN, 2006). La intensidad, derivada del cuadrado de la amplitud, puede verse influenciada por los parámetros del sistema radar y las características de los objetivos terrestres (PAN & SHI, 2023; GE et al., 2019). Por su parte, la coherencia permite analizar la correlación entre dos imágenes, proporcionando información clave sobre cambios en la superficie terrestre (WEI & SANWELL, 2010; ZEBKER & VILLASENOR, 1992). Estas herramientas ofrecen una base sólida para el monitoreo de eventos extremos como incendios forestales.

En este contexto, Chile sufrió en 2017 uno de los episodios de incendios forestales más devastadores de su historia, conocidos como los “megaincendios de 2017”. Estos eventos, agravados por una prolongada sequía de ocho años, condiciones meteorológicas extremas y una acumulación crítica de material combustible, arrasaron extensas áreas de ecosistemas nativos y plantaciones forestales en la zona central del país (CASTILLO et al., 2019; GONZALEZ et al., 2020; DELABARRERA & RUIZ, 2017). Entre ellos, el incendio denominado “Las Máquinas” se destacó por su magnitud y el impacto económico, social y ambiental que generó en la región del Maule. Este fenómeno extremo, caracterizado por velocidades de propagación inusuales y una intensidad energética sin precedentes, fue clasificado como un incendio de sexta generación o “tormenta de fuego” (MICHELETTI et al., 2018; BALOCCHI et al., 2020).

El uso de tecnología SAR en el estudio de incendios como “Las Máquinas” no solo facilita el análisis de áreas quemadas, sino que también permite evaluar el impacto en diferentes tipos de vegetación, incluyendo Bosque Esclerófilo, Bosque Espinoso



y Bosque Caducifolio, típicos de la región (VALENCIA et al., 2018; DELARD et al., 1998; SANTELICES et al., 2022; MUÑOZ & SANMARTIN, 2013). Además, la integración de datos de sensores SAR como Sentinel-1 y ALOS-2 ofrece una oportunidad única para desarrollar análisis temporales que abarcan desde el pre-evento hasta el post-evento, empleando técnicas avanzadas como composiciones RGB y procesamiento InSAR (SHIMADA & OSAWA, 2012; KANKAKU et al., 2015; NATSUAKI et al., 2016; TORRES, et al., 2012). Estas herramientas son fundamentales para mejorar nuestra comprensión del impacto de los incendios en los ecosistemas y para diseñar estrategias de mitigación más efectivas.

## 2. Objetivos

Este estudio tiene como objetivo principal evaluar la capacidad de los datos SAR para caracterizar y monitorear el impacto del incendio forestal “Las Máquinas” en la región del Maule. Mediante el análisis combinado de datos de intensidad y coherencia obtenidos de los satélites ALOS-2 y Sentinel-1, se busca identificar patrones de cambio en la cobertura terrestre y analizar las diferencias en los mecanismos de dispersión asociados al evento, contribuyendo así a un entendimiento más profundo de los procesos asociados a los incendios forestales.

## 3. Metodología

### 3.1 Área de estudio

El área de estudio se centró a la región del Maule, Chile, específicamente al sector afectado por el incendio forestal “Las Máquinas” (Figura 1) del año 2017. Este evento impactó a las comunas de Constitución, Pencahue, Empedrado, San Javier, Chanco y Cauquenes. El clima de esta región es típicamente mediterráneo, con una temperatura media anual de 13,7 °C (máxima en enero de 24,8 °C y mínima en julio de 5,9 °C) (SANTELICES et al., 2022). La Figura 1 presenta el polígono oficial delimitado por CONAF (Corporación Nacional Forestal, Chile), que ilustra el alcance del incendio forestal “Las Máquinas”. El tipo de vegetación que predomina en el área afectada corresponde a Bosque Espinoso, Bosque Esclerófilo y Bosque Caducifolio (VALENCIA et al., 2018; DELARD et al., 1998; MUÑOZ & SANMARTIN 2013; LUEBERT & PLISCOFF, 2017; FAUNDEZ et al., 2017; RODRIGUEZ et al., 2018; BUCHNER et al., 2018; SANTELICES et al., 2020).

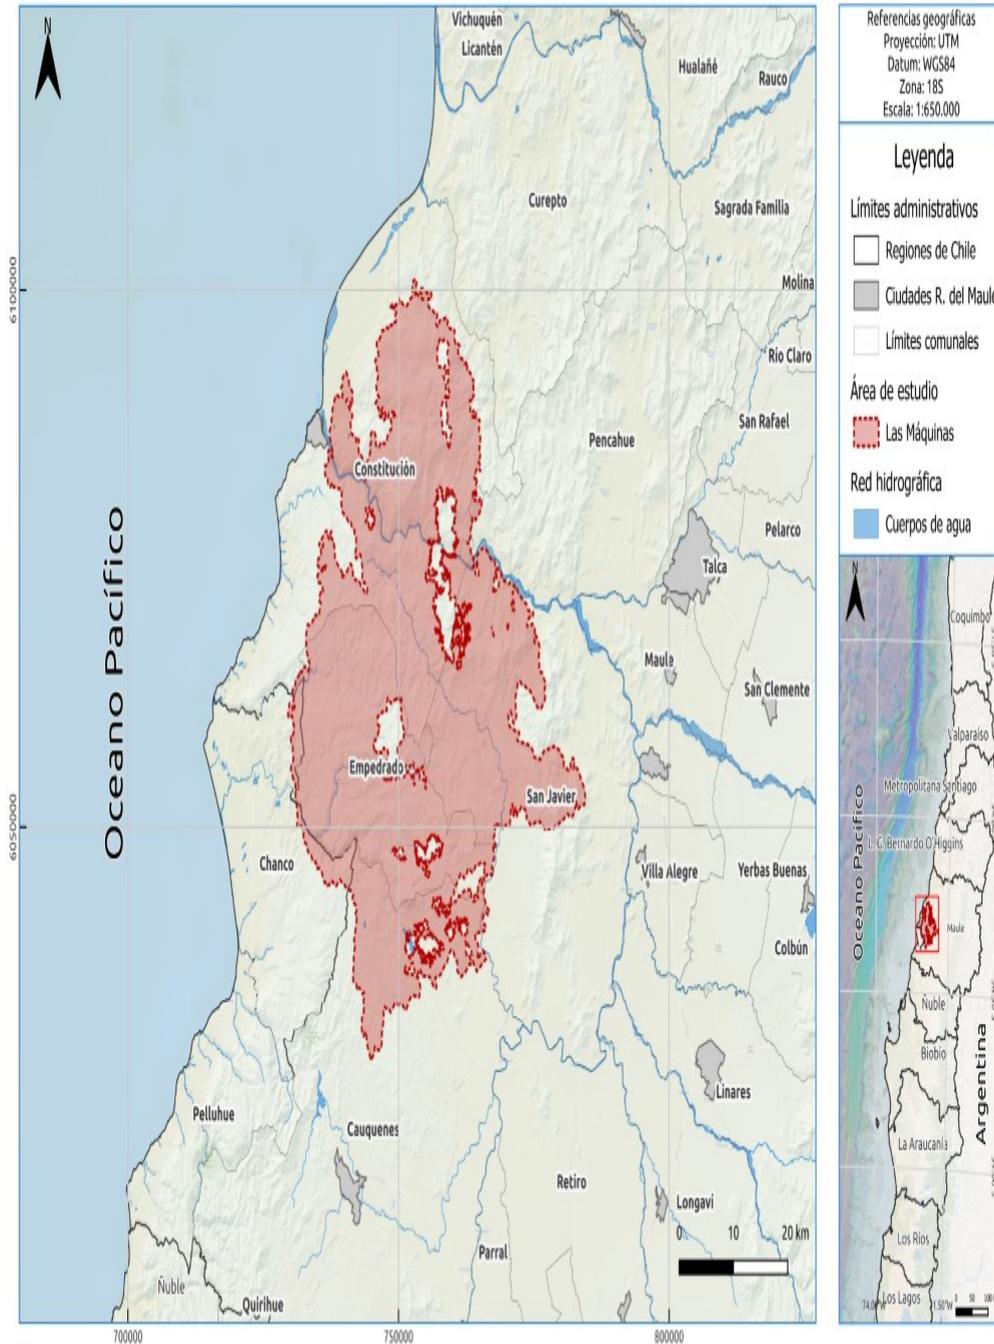


Figura 1. Área de estudio incendio forestal “Las Máquinas”, Maule, Chile

### 3.2. Adquisición de datos

Los datos empleados en este estudio incluyen imágenes satelitales del Advanced Land Observing Satellite-2 (ALOS-“DAICHI-2”), lanzado el 24 de mayo de 2014 desde el Centro Espacial Tanegashima mediante el cohete H-IIA (SHIMADA & OSAWA, 2012; KANKAKU et al., 2015). Este satélite presenta un ciclo de revisita frecuente de 14 días en ciertas zonas, lo que representa una mejora significativa respecto a su predecesor, el ALOS, cuyo ciclo era de 46 días (NATSUAKI et al., 2016). Sin embargo, la frecuencia de revisita depende de la disponibilidad específica para cada área geográfica.

También se utilizaron datos de los satélites Sentinel-1A y Sentinel-1B, parte de una misión SAR en banda C desarrollada dentro del programa Copernicus. Estos



satélites fueron lanzados en abril de 2014 y 2016 respectivamente, y ofrecen un tiempo de revisita de hasta 6 días (MARIN et al., 2020; FERNANDEZ-GUISURAGA et al., 2022). Para este análisis, se empleó el modo de adquisición Interferometric Wide Swath (IW), uno de los cuatro modos disponibles en Sentinel-1. Este modo utiliza el esquema TOPS SAR, que subdivide el área en tres subfranjas predefinidas (IW1, IW2 e IW3), cada una compuesta por una serie de ráfagas. Este diseño permite una cobertura terrestre de 250 km en la dirección transversal a la trayectoria, con una resolución espacial de 5 x 20 m (TORRES et al., 2012).

En total, se descargaron dos imágenes del ALOS-2 en modo ScanSAR y dos imágenes de Sentinel-1, seleccionando aquellas fechas que fueran similares entre sí (Tabla 1) y que sólo difieran por algunos días. Adicionalmente, para Sentinel-1 se utilizó únicamente el modo de adquisición descendente, ya que el modo ascendente solo estaba disponible en polarización simple (VV).

Tabla 1. Detalle de las imágenes radar adquiridas.

Satélite	Órbita	Fecha	Polarización
ALOS-2	Descendente	12-1-2017	HH/HV
		6-4-2017	
Sentinel-1	15-1-2017		VV/VH
		21-4-2017	

El preprocesamiento y procesamiento de los datos SAR e InSAR provenientes de ALOS-2 se llevó a cabo utilizando el AMSTer Software (DERAUW et al., 2020, D'OREYE et al. 2021, SAMSONOV, 2019). Para la clasificación supervisada basada en píxeles y su posterior validación, se emplearon el software QGIS (QGIS Geographic Information System, Open Source Geospatial Foundation Project) (QGIS, 2009) y el lenguaje de programación R, utilizando el paquete "caret", diseñado para el procesamiento y evaluación de clasificaciones supervisadas basadas en píxeles (R CORE TEAM, 2024), (KUHN, 2008).

### 3.3. Composición RGB: Intensidad + Coherencia

La intensidad (Int) corresponde a la información derivada de la amplitud de las ondas retrodispersadas. En términos matemáticos, este valor de intensidad se calcula como el cuadrado de la amplitud registrada en la imagen (MARTÍNEZ & MARCHAND, 2011; NATSUI et al., 2021; CLOSSON & MILISAVLJEVIC, 2017; SCHULT et al., 1988).

Por otro lado, la coherencia es una medida de la calidad de la fase interferométrica que permite definir la correlación entre dos imágenes SAR adquiridas (BHATTACHARYA et al., 2011) mediante la información en la fase de dos píxeles, que proporcionan valores en la coherencia en un rango de 0 a 1 (GENES & LOGAN, 2003). La pérdida de coherencia puede ser generada por dispersores inestables como el viento en el follaje, cambios en la cobertura del suelo o cambios en las propiedades dieléctricas (SEDZE et al., 2012). Desde un punto de vista matemático, la coherencia o correlación viene dada por (WEI & SANWELL, 2010):

$$\begin{aligned} & \backslash \text{begin}\{\text{align}*\} \\ & s_{\{1\}} = c + n_{\{1\}} \\ & s_{\{2\}} = c + n_{\{2\}} \end{aligned}$$



`\end{align*}`

$$s_1 = c + n_1$$

$$s_2 = c + n_2$$

donde:  $c$  es la parte correlacionada de la señal, y  $n_1$  y  $n_2$  son el ruido no correlacionado causado por factores de línea base, temporales, térmicos, de rotación y otros factores desconocidos. Entonces, una correlación entre dos imágenes viene dada por (ZEBKER & VILLASENOR, 1992; JUNGKYO et al., 2016; JACQUEMART & TIAMPO, 2020; SCOTT, et al., 2017):

`\begin{align*}`

$$\gamma = \frac{|\langle s_1 s_2^* \rangle|}{\sqrt{\langle s_1 s_1^* \rangle \langle s_2 s_2^* \rangle}}$$

`\end{align*}`

$$\gamma = \frac{|\langle s_1 s_2^* \rangle|}{\sqrt{\langle s_1 s_1^* \rangle \langle s_2 s_2^* \rangle}}$$

donde:  $s^*$  es el conjugado complejo de  $s$ , y  $\langle \rangle$  denota el promedio del conjunto.

Una vez calculada la intensidad y la amplitud, se realizó la composición de la capa ráster pre-evento (PRE) y la post-evento (POST), de la siguiente manera: R: PRE, G: POS y B: Coh.

#### 3.4. Clasificación supervisada basa en píxel

Posteriormente, se generó la composición Intensidad + Coh, y se delinearón polígonos de entrenamiento en QGIS para llevar a cabo una Clasificación Supervisada basada en Píxeles (MANCINI et al., 2024; ZARAZA, 2020), empleando el modelo Random Forest (RF) a través del paquete R caret (FEYISA, 2020; FILIPPA et al., 2022; MATEJČÍKOVA et al., 2024). El modelo RF utiliza dos parámetros clave (ZHOU et al., 2021): (1)  $mtry$ , que representa el número de variables predictoras utilizadas para dividir los datos en cada nodo; y (2)  $ntree$ , que corresponde al número total de árboles generados durante la ejecución del modelo. Esta metodología permite identificar y segmentar, en formato raster, las áreas afectadas por el Incendio Forestal. La selección del tamaño total de las muestras por clase se realizó siguiendo recomendaciones de estudios de teledetección que consideran el área total del mapa analizado (CONGALTON & GREEN, 2019; CONGALTON & GREEN, 2009; FOODY, 2009). En este contexto, se definieron tres clases principales: Incendio Forestal (IF), Vegetación (VG) y Suelo Desnudo (SD), descritas en la Tabla 2.

Tabla 2. Tamaño de muestra por clase Incendio Forestal (IF), Vegetación (VG) y Suelo Desnudo (SD).

Categorías	Tamaño de muestra
IF	110
VG	104
SD	106

Posteriormente, los datos de clasificación fueron convertidos a formato vectorial (.shp) usando el software QGIS con el objetivo de calcular la superficie en hectáreas (ha) para las combinaciones de polarización HH, HV, VV y VH (Intensidad + Coh).

### 3.5. Evaluación de precisión

Se utilizaron un total de 500 puntos aleatorios para la evaluación de precisión, empleando una matriz de confusión, con un rango de entre 75 y 100 puntos evaluados por clase en mapas de mayor complejidad o de áreas extensas (CONGALTON & GREEN, 2009). Los resultados obtenidos se validaron utilizando la precisión general, dos métricas ampliamente reconocidas en estudios de teledetección para clasificaciones supervisadas (AKAR & GUNGOR, 2012; KULKARNI & LOWE, 2016; SEKERTEKIN et al., 2017; CHETAN et al., 2017; BALU, 2019; NASIRI et al., 2023).

La precisión global, una estadística descriptiva más simple, se calcula dividiendo el total de clasificaciones correctas (suma de los elementos diagonales) entre el número total de píxeles en la matriz de confusión (CONGALTON, 1991). Esta métrica se obtiene mediante la siguiente fórmula (MAXWELL & WARNER, 2020; ISLAMI et al., 2022):

$$\text{Precisión global} = \frac{\text{Número de muestras clasificadas correctamente}}{\text{Número total de muestras}}$$

$$\text{Precisión global} = \frac{\text{Número de muestras clasificadas correctamente}}{\text{Número total de muestras}}$$

## 4. Resultados

### 4.1. Composición RGB: HH+Coh, HV+Coh, VV+Coh y VH+Coh

La Figura 2 muestra visualmente la composición RGB para Intensidad + Coh (HH), Intensidad + Coh (HV), Intensidad + Coh (VV) e Intensidad + Coh (VH) representados por las letras A, B, C y D, respectivamente.

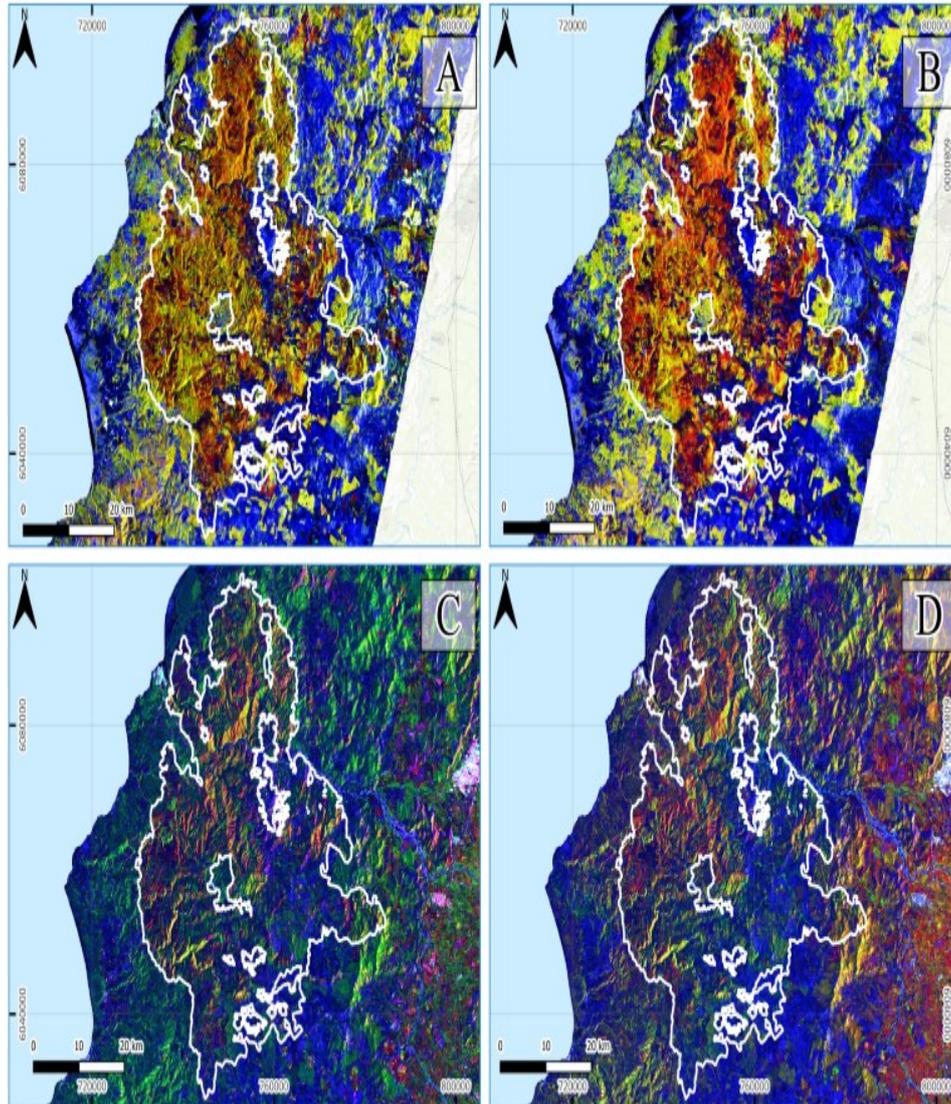


Figura 2. Resultado composición RGB de polarización: A) HH, B) HV, C) VV y D) VH.

Es importante destacar que, de estos cuatro resultados, solo las polarizaciones HH y HV mostraron una similitud precisa con respecto al polígono oficial generado por CONAF para el incendio “Las Máquinas”, debido principalmente a las características de la longitud de onda L utilizada por ALOS-2.

#### 4.2. Clasificación supervisada basada en píxel

La Figura 3 presenta el resultado vectorial de la categoría IF obtenido mediante la Clasificación Supervisada Basada en Píxeles, donde se aprecia con mayor claridad la delimitación del área afectada por el incendio forestal. La mayor superficie afectada corresponde a la polarización HH, con 116.066 ha, seguida de la polarización HV, con 100.657 ha. Posteriormente, la polarización VV registró 53.652 ha, mientras que la polarización VH mostró la menor superficie afectada, con 48.900 ha.

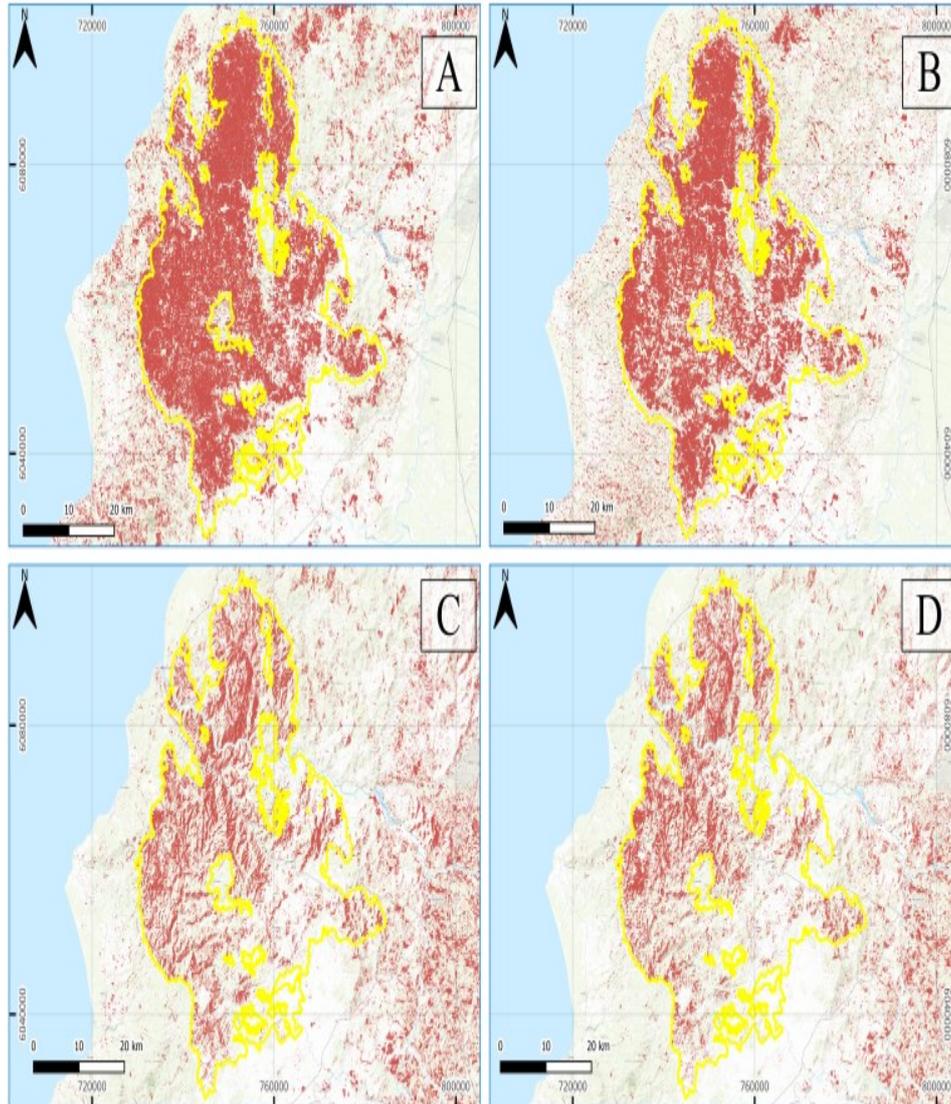


Figura 3. Resultado clasificación supervisada basada en píxel de polarización: A) HH, B) HV, C) VV y D) VH.

Por otro lado, al momento de realizar la evaluación de Precisión (tabla 3) la composición RGB que presentó mejores resultados en la evaluación fue POL HH. Luego continúa la polarización VV seguido de la polarización HV. Finalmente, el que presentó una menor exactitud fue VH.

Tabla 3. Métricas de precisión para cada una de las clasificaciones

Clasificación	Exactitud
POL HH	0,93
POL HV	0,92
POL VV	0,83
POL VH	0,85

Así mismo, la Figura 4, muestra los intervalos de confianza para cada banda HH, HV, VV y VH con respecto a su precisión. Los resultados de los intervalos de confianza demuestran que el mejor comportamiento en el rango mostrado corresponde a HH (0.88-0.98) y HV 0.88-0.94 de banda L, resultando las más adecuadas para este estudio, en comparación con las polarizaciones de banda C, VV (0.820-0.850) y VH (0.835-0.865).

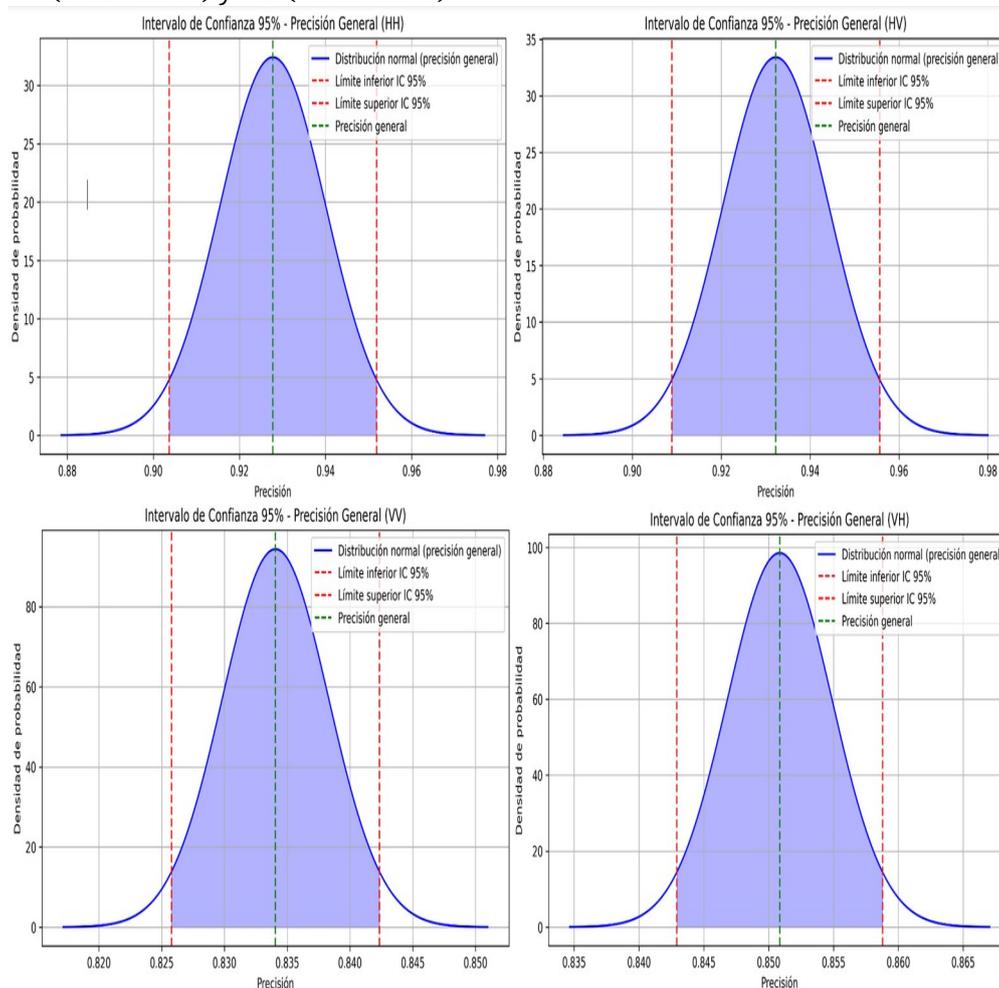


Figura 4. Intervalos de confianza para las polarizaciones HH, HV, VV y VH.

## 5. Discusión

Diversos estudios han demostrado la utilidad de los satélites SAR para el monitoreo de incendios forestales, particularmente en la delimitación de áreas quemadas y la evaluación de impactos mediante el uso de diferentes polarizaciones y análisis de coherencia (FERNANDEZ-GUISURAGA, 2022; CHELANGAT & CHANG, 2020). Las evaluaciones de precisión en clasificaciones basadas en tecnología SAR son fundamentales para garantizar la fiabilidad de los resultados, permitiendo además explorar cómo las distintas polarizaciones y su combinación ofrecen perspectivas complementarias. Recientemente, se ha destacado que el uso de múltiples polarizaciones y longitudes de onda, como las disponibles en ALOS-2 (HH y HV) y Sentinel-1 (VV y VH), mejora significativamente la caracterización de las áreas afectadas (ABDIKAN et al., 2022; ZHANG et al., 2024). Los resultados del estudio subrayan la superioridad de la polarización HH combinada con coherencia (HH+Coh) para detectar áreas afectadas por incendios forestales. Esta polarización mostró mayor sensibilidad hacia vegetación baja y suelos expuestos, identificando 7.649 ha más de superficie quemada en



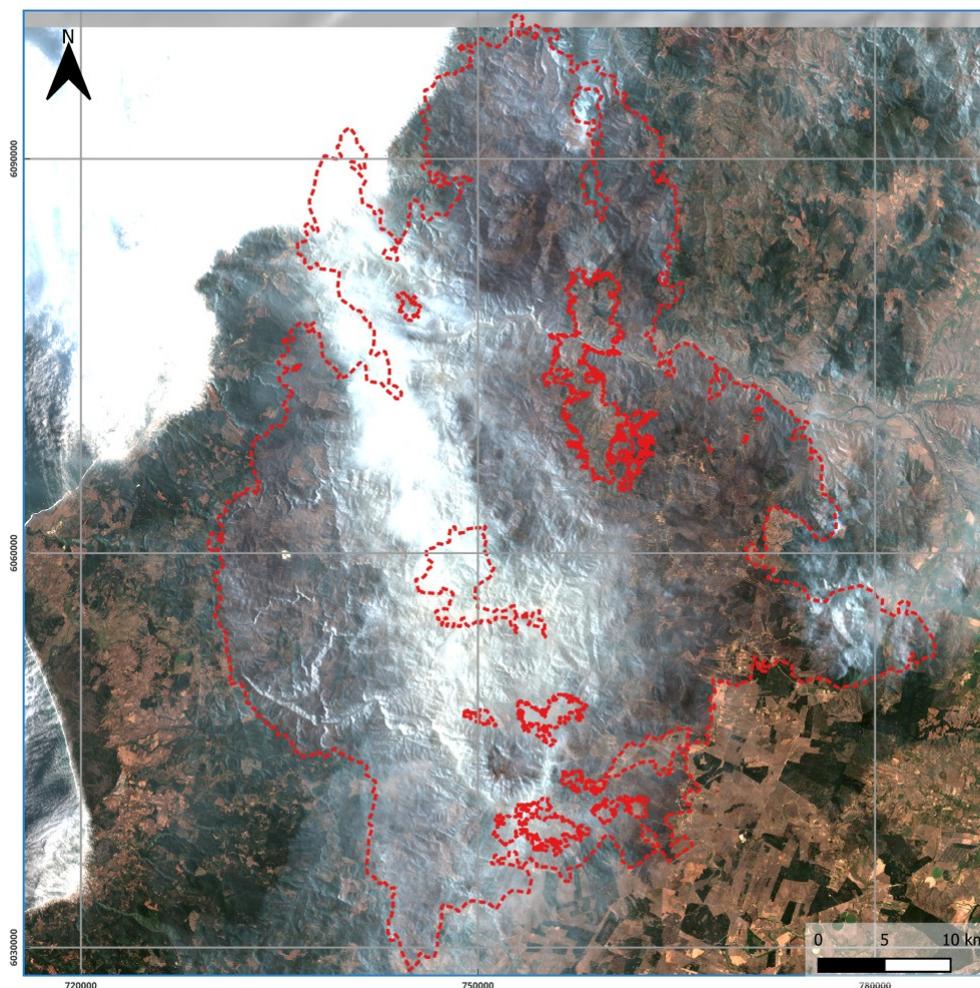
comparación con HV+Coh, que se orienta principalmente hacia estructuras verticales como árboles de gran tamaño. Esta diferencia refleja las características de la vegetación afectada y sugiere que gran parte de la zona estudiada experimentó una destrucción total, con árboles caídos y ramas quemadas. Estos cambios incrementaron significativamente la retrodispersión en la polarización HH, permitiendo capturar con mayor precisión las condiciones del terreno y los cambios provocados por el fuego. Sin embargo, la combinación de múltiples polarizaciones y parámetros, como la intensidad y la coherencia, resulta fundamental para obtener una perspectiva más robusta en el monitoreo de incendios forestales.

El análisis de delimitación de zonas afectadas mostró que las polarizaciones HH y HV de ALOS-2 y VV y VH de Sentinel-1 presentan diferencias en la cantidad de píxeles que identifican correctamente las áreas impactadas. No obstante, todas lograron una delimitación adecuada en comparación con el polígono oficial proporcionado por CONAF. Este comportamiento puede atribuirse a las características de interacción de las ondas SAR con la vegetación y el suelo, donde la banda L (ALOS-2) destaca por su capacidad para penetrar en áreas densamente vegetadas, mientras que la banda C (Sentinel-1) ofrece una resolución temporal más alta, aunque con limitaciones en resolución espacial (BALLING et al., 2024; FERNANDEZ-GUISURAGA et al., 2022). La banda L, gracias a su mayor longitud de onda, facilita una penetración más profunda en el dosel forestal, proporcionando datos valiosos sobre capas internas como ramas y troncos, e incluso sobre el suelo desnudo. En contraste, las bandas X o C, de menor longitud de onda, suelen limitarse a la caracterización de las copas de los árboles.

Adicionalmente, la combinación de parámetros como la intensidad y la coherencia en longitudes de onda larga (banda L) mejora la delimitación de áreas afectadas (ABDIKAN et al., 2022). Esto es relevante considerando que la resolución espacial de ALOS-2 en modo ScanSAR (100 m) permite una cobertura extensa por adquisición, aunque con menor resolución temporal comparada con Sentinel-1 (ZHANG et al., 2024). Mientras que Sentinel-1 ofrece imágenes cada 12 a 24 días, ALOS-2 puede tener intervalos de meses según la ubicación geográfica (YANAGIYA & FURUYA, 2020).

Estudios recientes evidencian la efectividad de combinar intensidad y coherencia para la delimitación de incendios, mejorando la precisión en etapas previas y posteriores al evento (ZHANG et al., 2019; MILLIN-CHALABI et al., 2014; RYKHUS & LU, 2011). Por ejemplo, la pérdida masiva de coherencia en la polarización VV puede utilizarse para clasificar imágenes y estimar daños en zonas afectadas (HRYSIEWICZ et al., 2023). Estos hallazgos sugieren que los productos SAR-InSAR no solo son útiles para el monitoreo post-evento, sino que también podrían integrarse en sistemas de alerta temprana (MICHAELIDES et al., 2024).

Aunque la tecnología SAR tiene ventajas clave, como su independencia de condiciones atmosféricas adversas (humo o nubes), enfrenta limitaciones, como la menor resolución temporal de ALOS-2. Por otro lado, los sensores ópticos, como Sentinel-2, ofrecen mayor frecuencia temporal, pero su efectividad se ve comprometida por la cobertura de humo durante incendios (ejemplo ilustrado en la Figura 4 con el incendio "Las Máquinas", 2017).



*Figura 5. Ejemplo de monitoreo con Sentinel 2 L2A en incendio forestal “Las Máquinas”, con fecha del 29 de enero de 2017*

A pesar de estas limitaciones, la integración de datos SAR-InSAR con imágenes ópticas representa un enfoque prometedor para mejorar la detección, delimitación y monitoreo de incendios forestales. Este enfoque combinado no solo ofrece una perspectiva más robusta para la gestión de desastres, sino que también abre nuevas oportunidades para el desarrollo de herramientas predictivas y de monitoreo multitemporal más efectivas.

## 6. Conclusiones

La percepción remota activa mediante tecnología SAR se consolida como una herramienta crucial para el monitoreo de incendios forestales, especialmente en escenarios donde las condiciones atmosféricas adversas, como la presencia de humo o nubes, limitan la efectividad de los sensores pasivos. Su capacidad para delimitar áreas afectadas, caracterizar el impacto del fuego y proporcionar datos continuos bajo condiciones variables refuerza su relevancia en la gestión de desastres. Este estudio evidencia que el potencial del SAR se amplifica mediante el uso de diferentes longitudes de onda, polarizaciones y frecuencias, lo que permite analizar de manera integral los mecanismos superficiales que interactúan con este tipo de sensores activos. El empleo de polarizaciones múltiples, como el Dual Pol analizado aquí, ofrece perspectivas complementarias al permitir explorar cómo los parámetros de retrodispersión y coherencia capturan las características estructurales y dinámicas de las áreas forestales.



## 7. Agradecimientos

Nos gustaría agradecer a la Agencia de Exploración Aeroespacial de Japón (JAXA) por proporcionar los datos de ALOS-2 para el presente estudio y al programa Copernicus por los datos de Sentinel 1.

## 8. Bibliografía

- ALARCON-AGUIRRE, G.** et al. 2022. Burn Severity Assessment Using Sentinel-1 SAR in the Southeast Peruvian Amazon, a Case Study of Madre de Dios. *Fire* 5.4.
- AKAR, O.; GUNGOR, O.** 2012. Classification of Multispectral Images Using Random Forest Algorithm. *Journal of Geodesy and Geoinformation* 1, pp. 105–112.
- AMITRANO, D.** et al. 2016. RGB SAR products: methods and applications. *European Journal of Remote Sensing* 40, pp. 777–793.
- AN, K.; JONES, C.; LOU, Y.** 2023. Developing a detection and monitoring framework for wildfire regimes with L-Band Polarimetric SAR.
- BALOCCHI, F.** et al. 2020. The effect of the ‘Las Maquinas’ wildfire of 2017 on the hydrologic balance of a high conservation value Hualo (*Nothofagus glauca* (Phil.) Krasser) forest in central Chile. *Forest Ecology and Management* 477, 118482.
- BALLING, J.** et al. 2024. ALOS-2 PALSAR-2 ScanSAR and Sentinel-1 data for timely tropical forest disturbance mapping: A case study for Sumatra, Indonesia. *Int. J. Appl. Earth Obs. Geoinf.* 132, p. 103994.
- BALU, B.** 2019. Pixel Based SAR Image Classification using Random Forest Algorithm. *Int. J. Innov. Technol. Explor. Eng.* 8, p. 1–7.
- BAN, Y.** et al. 2020. Near Real-Time Wildfire Progression Monitoring with Sentinel-1 SAR Time Series and Deep Learning. *Scientific Reports* 10.
- BERNHARD, E.-M.; TWELE, A.; GÄHLER, M.** 2011. Rapid Mapping of Forest Fires in the European Mediterranean Region - a Change Detection Approach Using X-Band SAR-Data. *Photogrammetrie - Fernerkundung - Geoinformation*, 261–270.
- BHATTACHARYA, A.; ARORA, M. & SHARMA, M.** 2011. Usefulness of synthetic aperture radar (SAR) interferometry for digital elevation model (DEM) generation and estimation of land surface displacement in Jharia coal field area. *Geocarto Int.* 27, pp. 1–21.
- BONDUR, V.; CHIMITDORZHIEV, T.; DMITRIEV, A.** 2023. A Step-Wise Workflow for SAR Remote Sensing of Perennial Heaving Mound/Crater on the Yamal Peninsula, Western Siberia. *Remote Sensing*.
- BUCHNER, C.** et al. 2018. Disponibilidad de madera de plantaciones de Pino radiata y Eucalipto (2017–2047).
- CAMPBELL, J.B.; WYNNE, R.H.** 2011. *Introduction to Remote Sensing, Fifth Edition*. Guilford Publications, 667 pp.
- CASTILLO SOTO, M.; SAAVEDRA, J.; BRULL, J.** 2019. Fire severity in mega wildfires in Chile in 2017: actions to improve the protection system. *Territorium: Revista Portuguesa de Riscos, Prevenção e Segurança*, 5–18.
- CHELANGAT, S. & CHANG, L.** 2020. Post-fire hazard detection using ALOS-2 radar and Landsat-8 optical imagery. *Geo-Inf. Disaster Manag. (Gi4DM); Surveying & Spatial Sci. Inst. (SSSI); Urban Resilience Asia Pacific 2 (URAP2)*.
- CHETAN, M.; DORNIK, A.; URDEA, P.** 2017. Comparison of Object and Pixel-based Land Cover Classification through three Supervised Methods. *Zeitschrift für Geodäsie, Geoinformation und Landmanagement* 5, pp. 265–270.
- CIGNA, F.** et al. 2013. Amplitude change detection with ENVISAT ASAR to image the cultural landscape of the Nasca region, Peru. *Archaeological Prospection* 20, pp. 117–131.
- CLOSSON, D.; MILISAVLJEVIC, N.** 2017. InSAR Coherence and Intensity Changes



- Detection. In: BEUMIER, C.; et al. (eds.), *Mine Action*. Rijeka: IntechOpen, Chap. 6.
- CONGALTON, R.; GREEN, K.** 2019. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Third Edition*.
- CONGALTON, R. G.; GREEN, K.** 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Second Edition*. Mapping Science. Taylor & Francis.
- CONGALTON, R.G.** 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* 37.1, pp. 35–46.
- CZUCHLEWSKI, K.R.; WEISSEL, J.K.** 2005. Synthetic aperture radar (SAR)-based mapping of wildfire burn severity and recovery. *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium*, 4 pp.
- DAGESTAD, K.-F.** et al. 2012. WIND RETRIEVAL FROM SYNTHETIC APERTURE RADAR - AN OVERVIEW. June.
- DELABARRERA, F.; RUIZ, V.** 2017. Evaluación del impacto de los incendios de Chile centro-sur ocurridos en el verano del año 2017 - Primera entrega.
- DELARD, C.; LOWEW, V.; CAMELIO, M. E.** 1998. Silvicultura de especies no tradicionales: una mayor diversidad productiva. *INFOR*.
- DERAUW, D.** et al. 2020. Ongoing automated ground deformation monitoring of Domuyo - Laguna del Maule area (Argentina) using Sentinel-1 MSBAS time series: Methodology description and first observations for the period 2015–2020. *Journal of South American Earth Sciences* 104, 102850.
- Derauw D., d'Oreye N., Jaspard M., Caselli A. and Samsonov S.** (2020) Ongoing automated Ground Deformation monitoring of Domuyo – Laguna del Maule area (Argentina) using Sentinel-1 MSBAS time series: Methodology description and first observations for the period 2015 – 2020. *J. South Am. Earth Sc.*, Vol. 104, 102850. <https://doi.org/10.1016/j.jsames.2020.102850> Freely available here: <https://www.sciencedirect.com/science/article/pii/S089598112030393X?via%3Dihub>
- d'Oreye N., D. Derauw, S. Samsonov, M. Jaspard, D. Smittarello** (2021) MASTER: A FULL AUTOMATIC MULTI-SATELLITE INSAR MASS PROCESSING TOOL FOR RAPID INCREMENTAL 2D GROUND DEFORMATION TIME SERIES. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS) 2021*, Brussels.
- FAUNDEZ, L.; FAUNDEZ, A.; FLORES, R.** 2017. Manual de reconocimiento de especies del DS N°68/MINAGRI, presentes en la región de Coquimbo.
- FERNANDEZ-GUISURAGA, J. M.** et al. 2022. ALOS-2 L-band SAR backscatter data improves the estimation and temporal transferability of wildfire effects on soil properties under different post-fire vegetation responses. *Science of The Total Environment*, 842, p. 156852.
- FEYISA, G. L.** et al. 2020. Characterizing and mapping cropping patterns in a complex agroecosystem: An iterative participatory mapping procedure using machine learning algorithms and MODIS vegetation indices. *Computers and Electronics in Agriculture* 175, p. 105595.
- FILIPPA, G.** et al. 2022. On the distribution and productivity of mountain grasslands in the Gran Paradiso National Park, NW Italy: A remote sensing approach. *International Journal of Applied Earth Observation and Geoinformation* 108, p. 102718.
- FITZGERALD, R.W. & LEES, B.G.** 1994. Assessing the classification accuracy of multisource remote sensing data. *Remote Sens. Environ.* 47.3, pp. 362–368.
- FOODY, G.** 2009. Sample size determination for image classification accuracy assessment and comparison. *International Journal of Remote Sensing* 30, p.
- GE, P.** et al. 2019. Study on the Intensity and Coherence Information of High-Resolution ALOS-2 SAR Images for Rapid Massive Landslide Mapping at a Pixel



- Level. *Remote Sensing* 11.23, pp. 2808–2822.
- GENES, T. & LOGAN, R.** 2003. Alaska Satellite Facility software tools Manual. *Geophys. Inst., Univ. Alaska Fairbanks*.
- GONZALEZ, M.** et al. 2020. Incendios forestales en Chile: causas, impactos y resiliencia.
- GONZALEZ, M.** et al. 2020. Incendios forestales en Chile: causas, impactos y resiliencia.
- HOEKMAN, D.** 2001. Monitoring tropical forests using Synthetic Aperture Radar. *The Balance between Biodiversity Conservation and Sustainable Use of Tropical Rain Forests*. Tropenbos International, 45–62.
- HRYSIEWICZ, A.** et al. 2023. SAR and InSAR data linked to soil moisture changes on a temperate raised peatland subjected to a wildfire. *Remote Sens. Environ.* 291, p. 113516.
- HU, X.** et al. 2023. GAN-based SAR and optical image translation for wildfire impact assessment using multi-source remote sensing data. *Remote Sensing of Environment* 289, 113522.
- ISLAMI, F.** et al. 2022. Accuracy Assessment of Land Use Change Analysis Using Google Earth in Sadar Watershed Mojokerto Regency. Jan. 2022.
- JACQUEMART, M.; TIAMPO, K.** 2020. Radar coherence and NDVI ratios as landslide early warning indicators.
- JOHNSY, A.C.** et al. 2023. Wildfire mapping with Interferometric ICEYE SAR data. *EGU General Assembly Conference Abstracts*, EGU-11914.
- JUNGKYO, J.** et al. 2016. Coherent Change Detection Using InSAR Temporal Decorrelation Model: A Case Study for Volcanic Ash Detection. *IEEE Transactions on Geoscience and Remote Sensing* 54, pp. 1–11.
- KANKAKU, Y.; SUZUKI, S.; SHIMADA, M.** 2015. ALOS-2 first year operation result. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 4121–4124.
- KIM, J.W.** 2013. Applications of Synthetic Aperture Radar (SAR)/ SAR Interferometry (InSAR) for Monitoring of Wetland Water Level and Land Subsidence.
- KUHN, M.** 2008. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28.5, pp. 1–26.
- KULKARNI, A. D.; LOWE, B.** 2016. Random Forest Algorithm for Land Cover Classification.
- KUMAR, V.** et al. 2022. Agricultural SandboxNL: A national-scale database of parcel-level processed Sentinel-1 SAR data. *Scientific Data* 9, 402.
- KURUM, M.** 2015. C-Band SAR Backscatter Evaluation of 2008 Gallipoli Forest Fire. *Geoscience and Remote Sensing Letters, IEEE* 12, 1091–1095.
- LANDIS, J. R. & KOCH, G. G.** 1977. The measurement of observer agreement for categorical data. *Biometrics* 33.1, pp. 159–74.
- LAVANDER, S.; LAVENDER, A.** 2015. *Practical Handbook of Remote Sensing*. Taylor & Francis, 319 pp.
- LUEBERT, F.; PLISCOFF, P.** 2017. *Sinopsis bioclimática y vegetal de Chile*. Biodiversidad (Editorial Universitaria (Chile)). Editorial Universitaria, S.A.
- LWIN, A.** 2006. GEOMORPHOLOGICAL MAPPING WITH RESPECT TO AMPLITUDE, COHERENCE AND PHASE INFORMATION OF ERS SAR TANDEM PAIR.
- MAFAZ, M.; WELIKANNA, D.** 2016. Comparative analysis on amplitude and coherence based change detection using ALOS PALSAR imagery.
- MANCINI, M.** et al. 2024. Pixel-based spatiotemporal statistics from remotely sensed imagery improves spatial predictions and sampling strategies of alluvial



soils. *Geoderma* 447, p. 116919.

**MARIN, C.** et al. 2020. Use of Sentinel-1 radar observations to evaluate snowmelt dynamics in alpine regions. *The Cryosphere*, 14, pp. 935–956.

**MARTÍNEZ, A.; MARCHAND, J.-L.** 2011. SAR Image Quality Assessment. *Revista de teledetección: Revista de la Asociación Española de Teledetección* 2.

**MATEJCÍKOVA, J.; VEBROVÁ, D.; SUROVÝ, P.** 2024. Comparative Analysis of Machine Learning Techniques and Data Sources for Dead Tree Detection: What Is the Best Way to Go? *Remote Sensing* 16.16, pp. 3086–3101.

**MAXWELL, A.E. & WARNER, T.A.** 2020. Thematic Classification Accuracy Assessment with Inherently Uncertain Boundaries: An Argument for Center-Weighted Accuracy Assessment Metrics. *Remote Sens.* 12.12, p. 1905.

**MICHAELIDES, R.** et al. 2024. Wildfire Progression Time Series Mapping With Interferometric Synthetic Aperture Radar (InSAR). *IEEE Geosci. Remote Sens. Lett.* 21, pp. 1–5.

**MICHELETTI, S.; ARAYA, C.; FIGUEROA, R.** 2018. Sistematización del proceso de reconstrucción post incendios forestales en la región del Maule.

**MILLIN-CHALABI, G.; MCMORROW, J. & AGNEW, C.** 2014. Detecting a moorland wildfire scar in the Peak District, UK, using synthetic aperture radar from ERS-2 and Envisat ASAR. *Int. J. Remote Sens.* 35, pp. 54–69.

**MUÑOZ VILLAGRA, M.; SAN MARTÍN, J.** 2013. Productos forestales no madereros de la región del Maule. *Universidad de Talca*, 1.

**MUTAI, S.; CHANG, L.** 2020. POST-FIRE HAZARD DETECTION USING ALOS-2 RADAR AND LANDSAT-8 OPTICAL IMAGERY. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* VI-3/W1-2020, 75–82.

**NAS, R.** et al. 2021. Sentinel-1 interferometric coherence and backscattering analysis for crop monitoring. *Computers and Electronics in Agriculture* 185, p. 106118.

**NASIRI, V.** et al. 2023. Comparing Object-Based and Pixel-Based Machine Learning Models for Tree-Cutting Detection with PlanetScope Satellite Images: Exploring Model Generalization. *Int. J. Appl. Earth Obs. Geoinf.* 125, p. 103555.

**NATSUAKI, R.** et al. 2016. SAR interferometry using ALOS-2 PALSAR-2 data for the Mw 7.8 Gorkha, Nepal earthquake. *Earth, Planets and Space*, 68.

**NATSUI, R.; JOSHI, G.; HIROSE, A.** 2021. SAR and optical sensor data fusion for earthquake damage assessment and analysis of the significant features.

**PAN, B.; SHI, X.** 2023. Fusing Ascending and Descending Time-Series SAR Images with Dual-Polarized Pixel Attention UNet for Land-slide Recognition. *Remote Sensing* 15.23, pp. 5619–5634.

**PATRA, S.** et al. 2006. A technique for generating natural colour images from false colour composite images. *International Journal of Remote Sensing* 27, pp. 2977–2989.

**PETROVSKA, I. & DIMOV, L.** 2020. Accuracy assessment of unsupervised land cover classification. *Sci. J. Civil Eng.* 9, p. 83–88.

**QGIS DEVELOPMENT TEAM.** 2009. QGIS Geographic Information System. Open Source Geospatial Foundation. Disponible en: <http://qgis.osgeo.org>.

**R CORE TEAM.** 2024. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria. Disponible en: <https://www.R-project.org/>.

**RODRIGUEZ, R.** et al. 2018. Catálogo de las plantas vasculares de Chile. *Gayana. Botánica*, 75, pp. 1–430.

**RYKHUS, R. & LU, Z.** 2011. Monitoring a boreal wildfire using multi-temporal Radarsat-1 intensity and coherence images. *Geomatics Nat. Hazards Risk*, pp. 15–



32.

- SAMSONOV, S.** (2019) User manual, source code, and test set for MSBASv3 (Multidimensional Small Baseline Subset version 3) for one- and two-dimensional deformation analysis <https://doi.org/10.4095/313749>
- SANTELICES MOYA, R.** et al. 2022. Assessment of a wildfire in the remaining *Nothofagus alessandrii* forests, an endangered species of Chile, based on satellite Sentinel-2 images. *International Journal of Agriculture and Natural Resources* 49.
- SANTELICES MOYA, R.** et al. 2022. Assessment of a wildfire in the remaining *Nothofagus alessandrii* forests, an endangered species of Chile, based on satellite Sentinel-2 images. *International Journal of Agriculture and Natural Resources*, 49.
- SANTELICES MOYA, R.** et al. 2020. Variación intraespecífica en *Nothofagus glauca*, una especie endémica de los bosques mediterráneos de Chile. *Bosque (Valdivia)*, 41, pp. 221–231.
- SCHULT, R.; HENYEY, F.; WRIGHT, J.** 1988. Imaging of Ocean Waves by SAR. p. 42.
- SCOTT, C.; LOHMAN, R.; JORDAN, T.** 2017. InSAR constraints on soil moisture evolution after the March 2015 extreme precipitation event in Chile. *Scientific Reports* 7, p. 5123.
- SEDZE, M.** et al. 2012. L-band InSAR decorrelation analysis in volcanic terrains using airborne LiDAR data and in situ measurements: The case of the Piton de la Fournaise volcano, France. In: *IEEE IGARSS 2012*, pp. 3907–3910.
- SEKERTEKIN, A.; MARANGOZ, A.; AKCIN, H.** 2017. PIXEL-BASED CLASSIFICATION ANALYSIS OF LAND USE LAND COVER USING SENTINEL-2 AND LANDSAT-8 DATA. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-4/W6*, pp. 91–93.
- SHIMADA, M.; OSAWA, Y.** 2012. ALOS-2 science program and high resolution SAR applications. *Proceedings of SPIE - The International Society for Optical Engineering*, pp. 12.
- TANASE, M.** et al. 2010. Sensitivity of X-, C-, and L-Band SAR Backscatter to Burn Severity in Mediterranean Pine Forests. *Geoscience and Remote Sensing, IEEE Transactions on* 48, 3663–3675.
- TORRES, R.** et al. 2012. GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, pp. 9–24.
- VALENCIA, D.** et al. 2018. Severidad del daño causado por los incendios forestales en los bosques remanentes de *Nothofagus alessandrii* Espinosa en la Región del Maule de Chile. *Gayana. Botánica*. 75, 531–534.
- WEI, M.; SANWELL, D. T.** 2010. Decorrelation of L-Band and C-Band Interferometry Over Vegetated Areas in California. *IEEE Transactions on Geoscience and Remote Sensing* 48.7, pp. 2942–2952.
- YANAGIYA, K. & FURUYA, M.** 2020. Post-Wildfire Surface Deformation Near Batagay, Eastern Siberia, Detected by L-Band and C-Band InSAR. *J. Geophys. Res. Earth Surf.* 125, p. 113516.
- ZARAZA AGUILERA, M. A.** 2020. CLASSIFICATION OF LAND-COVER THROUGH MACHINE LEARNING ALGORITHMS FOR FUSION OF SENTINEL-2A AND PLANETSCOPE IMAGERY. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-3/W12-2020*, pp. 361–368.
- ZEBKER, H. A.; VILLASENOR, J.** 1992. Decorrelation in interferometric radar echoes. *IEEE Transactions on Geoscience and Remote Sensing* 30.5, pp. 950–959.
- ZHANG, P.** 2020. Deep Learning for Wildfire Progression Monitoring Using SAR and Optical Satellite Image Time Series. Jan. 2020.
- ZHANG, P.** et al. 2024. Assessing Sentinel-2, Sentinel-1, and ALOS-2 PALSAR-2 Data for Large-Scale Wildfire-Burned Area Mapping: Insights from the 2017–2019



Canada Wildfires. *Remote Sensing*.

**ZHANG, P.** et al. 2019. An implicit radar convolutional burn index for burnt area mapping with Sentinel-1 C-band SAR data. *ISPRS J. Photogramm. Remote Sens.* 158, pp. 50–62.

**ZHOU, H.** et al. 2021. A Hybrid Approach of Combining Random Forest with Texture Analysis and VDVI for Desert Vegetation Mapping Based on UAV RGB Data. *Remote Sensing* 13.10, pp. 1891–1906.