

CONAMA 2024

CONGRESO NACIONAL DEL MEDIO AMBIENTE

Integración de datos SAR de ALOS
PALSAR y Sentinel-1 para la estimación
precisa de la biomasa aérea en
bosques del sur de Chile



CONAMA 2024

TÍTULO

Autor Principal: Pablo Alejandro Martínez (Universidad Católica de Ávila)

Otros autores: Cristina Gómez (Universidad de Valladolid); Georgina Trujillo (CONAF Chile);
Javier Velázquez Saornil (Universidad Católica de Ávila)

RESUMEN

Presentamos los esfuerzos iniciales de desarrollo de una metodología para estimar la biomasa forestal aérea en bosques nativos de las regiones del sur de Chile, donde la cobertura nubosa es casi permanente, utilizando una combinación de datos radar de apertura sintética (SAR) de ALOS PALSAR y Sentinel-1. La investigación se centra en mejorar la interpretación de las señales de microondas (banda L, 1.270 GHz y banda C, 5.405 GHz) para proporcionar estimaciones más precisas de biomasa forestal.

En la fase inicial de la investigación, se emplearon mosaicos anuales de ALOS PALSAR en banda L de los años 2010 y 2015 para estimar el volumen y la biomasa aérea con una resolución espacial de 0.06 ha y evaluar los cambios a lo largo del tiempo. Las polarizaciones HH y HV, junto con algunas variables derivadas, se introdujeron en algoritmos K-NN calibrados con datos de campo del inventario nacional forestal continuo, para estimar la distribución espacial de los depósitos de carbono en 42 000 km² de bosques de diversos tipos. Los resultados indicaron una variabilidad significativa en el contenido de carbono entre los distintos tipos de bosque, siendo los bosques de Lenga (*Nothofagus pumilio*) los que mostraron mayores cantidades de carbono almacenado en biomasa aérea. Nuestros estudios piloto, realizados en las regiones de Magallanes, Aysén y Los Lagos, demostraron la capacidad de los datos de ALOS PALSAR para proporcionar estimaciones precisas de biomasa aérea y detectar cambios en la estructura forestal y el contenido de carbono.

Al integrar datos SAR en banda C de Sentinel-1, pretendemos utilizar la información complementaria de diferentes longitudes de onda para mejorar la precisión del análisis de la estructura forestal. Los datos en banda C proporcionan información sobre la estructura del dosel, mientras que la mayor longitud de onda de los datos en banda L, que penetra más profundamente en el dosel forestal, proporcionan detalles sobre el contenido de biomasa en troncos y ramas inferiores. Empleamos métodos sólidos para caracterizar la estructura forestal a pesar de distorsiones como el ruido y las diferentes condiciones de iluminación. Esperamos que esta integración proporcione una representación más detallada de las estimaciones de biomasa forestal y de las reservas de carbono.

INTRODUCCIÓN

Los bosques del sur de Chile, particularmente aquellos en áreas de las regiones administrativas de Aysén y Magallanes, presentan desafíos para el seguimiento de la biomasa aérea forestal (AGB, por sus siglas en inglés) y la estimación de las reservas y emisiones de carbono. Chile estableció el período de 2001 a 2010 como referencia para las emisiones forestales, definiéndolo como el estándar para evaluar las emisiones en los seguimientos posteriores. La estimación de la AGB mediante métodos tradicionales basados en la adquisición de datos de campo presenta con frecuencia limitaciones de accesibilidad debido al extenso y accidentado terreno y a la densidad de la vegetación. Además, la disponibilidad limitada de datos o el muestreo con intensidad irregular derivado de la difícil accesibilidad lleva a una subestimación o sobreestimación de la AGB y de las reservas de carbono (Pascual et al., 2024; Pérez-Quezada et al., 2023).

La teledetección ofrece oportunidades únicas para la estimación de la biomasa aérea forestal con detalle espacial y localización explícita, cumpliendo con las recomendaciones del IPCC para un enfoque de nivel 3. Combinando tecnologías avanzadas de teledetección con datos de campo provenientes de los Inventarios Forestales Nacionales (IFN) se mejora la precisión y fiabilidad de las estimaciones de atributos forestales como la biomasa o la composición de especies. Este aumento en la precisión de las evaluaciones de biomasa contribuye a una gestión forestal más eficaz y a la formulación de políticas mejor fundamentadas (Urbazaev et al., 2018; Novo-Fernández et al., 2019; Yu et al., 2022).

La biomasa aérea puede estimarse eficazmente mediante datos de retrodispersión de Radar de Apertura Sintética (SAR), especialmente en bosques densos donde los métodos tradicionales presentan limitaciones importantes (Ji et al., 2020). Las observaciones en banda L destacan en la estimación de biomasa forestal debido a su capacidad para penetrar las copas de los árboles (Santoro et al., 2019; Tamiminia et al., 2022; Santi et al., 2020). Además, la integración de datos SAR multi-temporales y multi-frecuencia puede mejorar significativamente la precisión frente a enfoques basados en una sola imagen, especialmente en zonas forestales heterogéneas. Estos enfoques multi-frecuencia son sensibles a la complejidad de la estructura forestal, mejorando la precisión de la estimación de biomasa (Santoro & Cartus, 2028; Santoro et al., 2019; Jesus & Kuplich, 2020).

Las técnicas de aprendizaje automático o machine learning se han empleado para optimizar la estimación de AGB con datos SAR multifrecuencia (Tamiminia et al., 2022; Santi et al., 2020) y superar, hasta cierto punto, la tendencia a la subestimación debida al efecto de saturación en niveles altos de biomasa. Numerosos trabajos han demostrado la eficacia de los métodos de K-vecinos más cercanos (K-NN) en la estimación de biomasa en bosques heterogéneos, al utilizar datos satelitales ópticos y SAR, compensando la escasez de datos de inventario en campo (Zhang et al., 2022; Nguyen et al., 2018; Breidenbach et al., 2021). Por ejemplo, Liu (2024) comparó el desempeño del método K-NN frente a otros métodos de aprendizaje automático como Bagging y Random Forest, para la estimación de reservas de carbono, concluyendo que K-NN ofrecía resultados similares a los otros métodos. Los avances recientes en técnicas de aprendizaje automático, incluidos los enfoques K-NN y otros modelos estadísticos, se muestran prometedores para la mejora de la precisión de la estimación de biomasa, especialmente en áreas con datos de campo limitados (Kennedy et al., 2018). Estos métodos aprovechan eficazmente los datos de teledetección disponibles para suplir las limitaciones de los enfoques de inventario tradicionales, facilitando un seguimiento más preciso.

Actualmente se dispone de gran cantidad de datos de teledetección de alta calidad, lo que permite una mayor precisión en las estimaciones actuales. Sin embargo, la estimación retrospectiva de biomasa aérea sigue siendo un desafío en períodos con datos limitados. Esta comunicación presenta una metodología para estimar la AGB en dos fechas de referencia (2010 y 2015) aprovechando relaciones estadísticas entre los datos SAR en banda L de los sensores PALSAR y los datos de parcelas de inventario forestal. La metodología, validada en áreas piloto, muestra un gran potencial para una aplicación a mayor escala. Aprovechando la continuidad en la adquisición de datos por PALSAR y la amplia disponibilidad de datos SAR de Sentinel-1 a través del programa Copernicus, proponemos integrar los datos en banda L de PALSAR con los de banda C de Sentinel-1 para mejorar la precisión en la estimación de AGB.

MÉTODOS

Zona de estudio

Se establecieron tres zonas piloto (Figura 1), una por cada región administrativa del sur de Chile (Los Lagos, Aysén, y Magallanes), de forma que los tipos más importantes de bosque nativo en cada región estuvieran representados. Entre los tipos de bosque considerados, los más abundantes son Lengua (*Nothofagus pumilio*), Siempreverde, y Coihue de Magallanes (*Nothofagus betuloides*), que representan aproximadamente el 75% del total de bosque nativo en Chile. Mientras que Los Lagos se caracteriza por la dominancia de bosques templados, en Aysén y Magallanes predominan los bosques subantárticos de especies tolerantes al frío extremo.

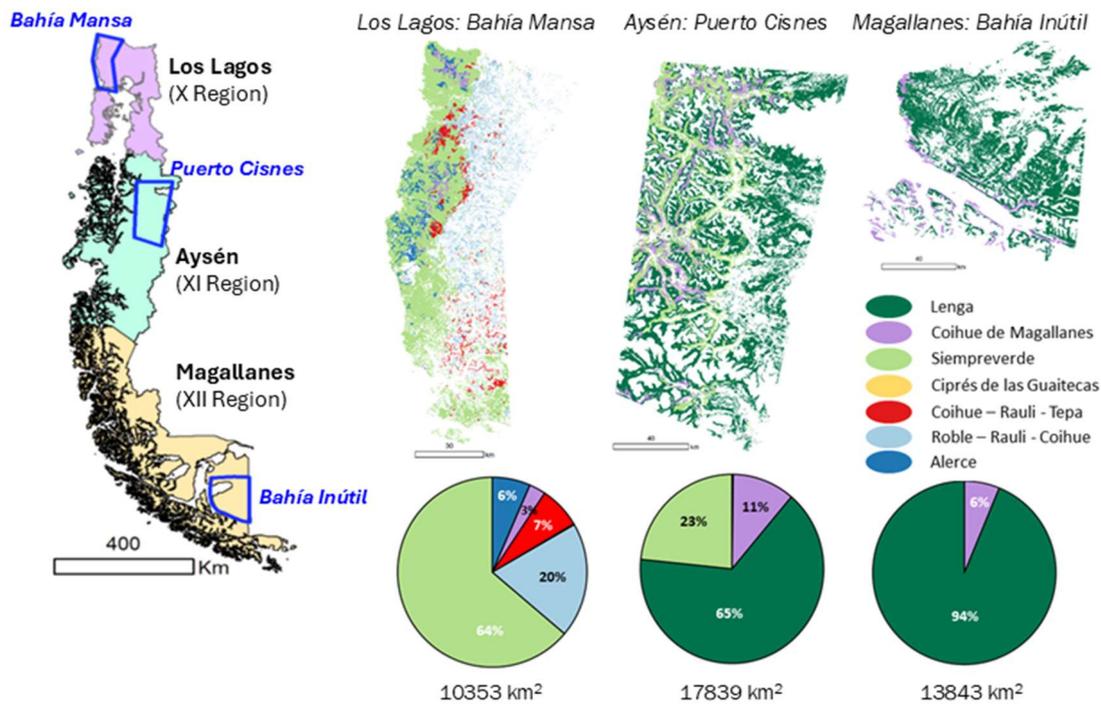


Figura 1. Zona de estudio. Izda: localización de las zonas piloto; dcha: distribución de tipos de bosque en las zonas piloto.

La superficie total de las zonas piloto es aproximadamente 42 000 km². Puesto que ALOS PALSAR proporciona datos espaciales de toda la superficie, el factor determinante para elegir las zonas piloto fue la disponibilidad de datos de inventario en campo, necesarios para calibrar y validar los modelos de estimación.

Datos de Inventario Nacional Forestal Continuo

INFOR lleva a cabo el Inventario Nacional Forestal Continuo en Chile, que consiste en la adquisición de mediciones periódicas en campo de una serie de parámetros. Entre las variables medidas se incluyen el diámetro a 1.30m, volumen, área basal y número de árboles por hectárea. Las parcelas permanentes de inventario se agrupan en clústeres de 2-3 localizaciones separadas entre sí menos de 100 m. Además, se toman cores o canutos de algunos árboles que permiten caracterizar el crecimiento anual.

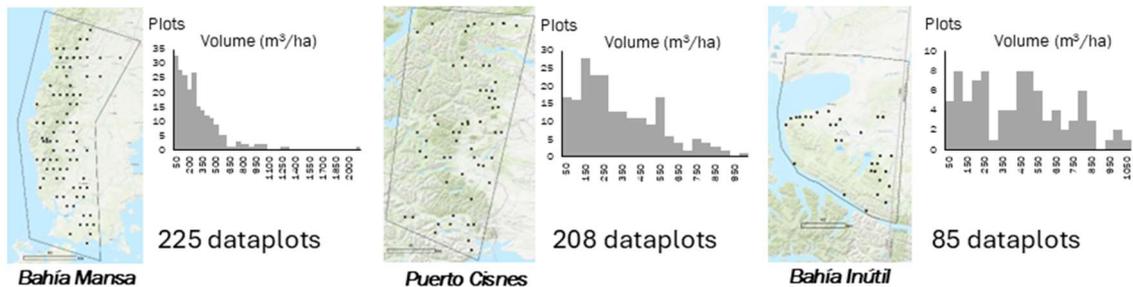


Figura 2. Distribución espacial de parcelas de inventario forestal continuo y distribución estadística de valores de volumen (m³/ha) medidos en campo

Los factores de crecimiento anual, calculados a partir de los anillos de crecimiento de los últimos 10-15 años en cores cilíndricos extraídos con barrena, permiten extrapolar las estimaciones de volumen a fechas distintas a las de medición en campo. Las mediciones de 2010 y 2015 se utilizaron para evaluar el volumen forestal por hectárea en cada una de estas zonas. Estas medidas nos permiten estimar cambios en la estructura forestal a lo largo del tiempo a través de técnicas de extrapolación, para alinearlas con los datos adquiridos por los satélites. Los datos de localización de las parcelas se encuentran disponibles en la web de INFOR (<https://ifn.infor.cl/index.php/datos-primer-ciclo>).

La intensidad de muestreo fue distinta en cada una de las zonas de estudio y también según tipos de bosque, debido sobre todo a factores de accesibilidad.

Datos ALOS PALSAR

Para modelizar el volumen y AGB inicialmente utilizamos datos SAR en banda L del sensor PALSAR (Phased Array type) a bordo de las plataformas satelitales ALOS (Advanced Land Observing Satellite). PALSAR opera en frecuencia 1.207 GHz (longitud de onda 23.6 cm) y en nuestras fechas de referencia adquirió datos con doble polarización (HH + HV), es decir, con un canal emitiendo y recibiendo energía polarizada horizontalmente y otro canal emitiendo horizontal y recibiendo vertical. Utilizamos datos de PALSAR-1, operativo entre 2006 y 2011, cuyo periodo de revisita era de 46 días y datos de PALSAR-2, operativo desde 2014 hasta la actualidad, con periodo de revisita de 14 días. Obtuvimos datos en formato FBD (Fine Beam Dual) del repositorio de ASF (Alaska Satellite Facility) para estratificar los tipos forestales de acuerdo a una clasificación no supervisada de variables polarimétricas conocida como Alpha Wishar Dual Pol. La modelización estadística y cartografiado de las variables de interés (volumen

y AGB) se hizo con datos de los mosaicos anuales PALSAR para los años de referencia, 2010 y 2015.

Los mosaicos PALSAR están procesados con tamaño de pixel de 25 m e incluyen datos de múltiples fechas de adquisición. Por ejemplo, el mosaico de 2010 está compuesto por 39 adquisiciones a lo largo de 127 días, mientras que el mosaico de 2015 fue construido a partir de datos de 42 adquisiciones distribuidas en 441 días. La mayor dispersión temporal del mosaico 2015 puede haber introducido incertidumbre en los modelos, ya que la estructura forestal pudo variar en ese periodo de adquisición de datos. Los mosaicos SAR se calibraron radiométrica y geoméricamente, incluyendo una normalización por la geometría de adquisición y las condiciones ambientales.

Los valores de los mosaicos se convirtieron a valores sigma utilizando la siguiente ecuación (1):

$$\sigma = 10 \log(DN^2) + CF \quad \text{ec. 1}$$

Donde DN se refiere a los niveles digitales, y CF es un factor de calibración (Shimada et al. 2009).

A partir de los mosaicos de ALOS PALSAR se derivaron las variables independientes para los modelos estadísticos, a saber: coeficientes de retrodispersión (HH, HV), la ratio de ambos (HH/HV), y un índice estructural conocido como Radar Forest Degradation Index (RFDI) (Mitchard et al. 2012).

Modelización con ALOS PALSAR

Se desarrollaron modelos estadísticos para relacionar las variables SAR con las medidas de volumen y AGB tomadas en campo. Estos modelos se construyeron de forma individual para cada tipo de bosque y cada fecha de referencia, de forma que se incorpora en ellos las variaciones de estructura, la penetración de la señal SAR y los cambios forestales a lo largo del tiempo. El modelo elegido, dadas las características de los datos disponibles, en particular el reducido número de datos de referencia, fue el K-NN.

El contenido de carbono (C) se estimó a partir del volumen utilizando la siguiente ecuación:

$$C = V \times BEF \times D \times FC \quad \text{ec. 2}$$

Donde C indica contenido de carbono (T/ha), V es volumen forestal (m³/ha), BEF es factor de expansión de biomasa, D es densidad media de la madera (T/m³) y FC es fracción de carbono en materia seca (0.5).

También se evaluó el flujo de CO₂ equivalente para cada pixel durante el periodo 2010-2015 calculando la diferencia de contenido de C entre dos fechas de referencia y aplicando el factor de conversión de C a CO₂. El flujo anual de CO₂ se calculó promediando el flujo de C entre los cinco años.

$$CO_2 = (C_{2015} - C_{2010}) \times \frac{44}{12} \quad \text{ec. 3}$$

$$CO_2 \text{ anual} = \frac{CO_2}{\text{period}}$$

ec. 4

Reconociendo que una de las fuentes de incertidumbre más relevantes es la falta de sincronía entre los datos de campo y las observaciones SAR, los datos medidos en campo se actualizaron a fecha de referencia gracias a los factores de crecimiento. La incertidumbre espacial se minimizó gracias a una georeferenciación precisa, buscando que el dato de campo esté relacionado con el valor del pixel correcto.

La validación de los modelos se hizo mediante técnicas de validación cruzada, separando el conjunto de datos en submuestras de entrenamiento y validación. Los resultados de la modelización se evaluaron por su capacidad para predecir volumen y AGB de la submuestra de validación, con métricas como R^2 , RMSE, y sesgo. Los resultados demostraron que existe alta correlación entre los datos SAR y las medidas de campo, aunque la precisión estaba influida por la distribución temporal y espacial de los datos.

Integración de datos Sentinel-1 para mejorar las estimaciones de volumen y biomasa forestal

Sentinel-1 es una constelación con dos satélites gemelos operando simultáneamente que forma parte del programa Copernicus de la Comisión Europea, desarrollado por la Agencia Espacial Europea. Los dos satélites gemelos Sentinel-1 llevan un sensor SAR en banda C que opera a una frecuencia de 5.405 GHz (longitud de onda de 5.56 cm). Los sensores tienen capacidad para funcionar con doble polarización VV + VH, lo que permite a Sentinel-1 adquirir información en dos canales: el canal VV, por el que el sensor emite y recibe la señal polarizada verticalmente y el canal VH por el que el sensor emite en vertical y recibe en horizontal. El canal VH, de polarización cruzada, es más sensible a la retrodispersión volumétrica y en particular a la estructura de la cubierta forestal (Udali et al. 2021). El modo de adquisición de datos por defecto sobre zonas terrestres es IW (Interferometric Wide swath), que proporciona datos con resolución espacial de 5 x 20m y resolución temporal nominal de 6 días cuando los dos sensores operan simultáneamente (Torres et al. 2012). Nuestra metodología persigue la integración de datos PALSAR y Sentinel-1 a través de la homogeneización de los datos en distinta frecuencia.

RESULTADOS

Modelización

Algunos resultados de la modelización estadística se resumen en el cuadro 1, que recoge los valores de ajuste de los modelos mediante la métrica R^2 y los errores mediante las métricas MAE (error absoluto medio) y RMSE (raíz cuadrada del error medio). Estos tres parámetros han sido evaluados con los valores de entrenamiento y test de las muestras.

Cuadro 1. Resultados de los modelos K-NN en las zonas piloto

| Modelo | R ² (train/test) | MAE (train/test) | RMSE | Tipo forestal |
|-----------------|-----------------------------|------------------|-----------------|--|
| Los Lagos 2010 | 0.99 / 0.61 | 5.08 / 132.65 | 15.13 / 174.89 | <i>Siempreverde</i> |
| | 0.91 / 0.59 | 21.62 / 69.40 | 48.69 / 72.42 | <i>Roble raulí</i> |
| | 0.78 / 0.49 | 55.38 / 58.08 | 114.73 / 77.13 | <i>Coihue raulí</i> |
| | 0.92 / 0.75 | 39.61 / 85.51 | 66.23 / 111.27 | <i>Alerce</i> |
| Los Lagos 2015 | 0.99 / 0.71 | 5.13 / 121.18 | 15.16 / 155.96 | <i>Siempreverde</i> |
| | 0.99 / 0.61 | 15.13 / 91.18 | 25.16 / 142.96 | <i>Roble raulí</i> |
| | 0.75 / 0.51 | 75.40 / 92.38 | 123.22 / 103.58 | <i>Coihue raulí</i> |
| | 0.96 / 0.51 | 26.44 / 150.45 | 49.92 / 167.84 | <i>Alerce</i> |
| Aysén 2010 | 0.86 / 0.34 | 28.50 / 95.56 | 70.72 / 128.55 | <i>Lenga</i> |
| | 1.00 / 0.38 | 0.00 / 130.77 | 0.00 / 153.58 | <i>Coihue</i> |
| | 0.96 / 0.59 | 11.27 / 107.71 | 40.63 / 122.85 | <i>Siempreverde</i> |
| Aysén 2015 | 0.91 / -0.28* | 16.61 / 181.03 | 51.38 / 219.48 | <i>Lenga</i> |
| | 1.00 / 0.64 | 0.00 / 103.57 | 0.00 / 129.36 | <i>Coihue</i> |
| | 0.96 / -1.20* | 12.20 / 167.70 | 42.29 / 224.18 | <i>Siempreverde</i> |
| Magallanes 2010 | 0.98 / 0.66 | 13.01 / 119.81 | 33.40 / 150.25 | <i>Lenga + Coihue</i> <i>Magallanes</i> |
| Magallanes 2015 | 0.98 / 0.56 | 13.60 / 135.47 | 34.39 / 174.61 | <i>Lenga + Coihue</i> <i>Magallanes</i> |

Cartografía de variables de interés

Los modelos de los tipos forestales Siempreverde, Coihue-Raulí, Coihue de Magallanes, Lenga, Roble raulí se aplicaron sobre la superficie con cobertura de tipo forestal para el cual habían sido desarrollados. Para hacer esta aplicación se definieron máscaras espaciales determinando esas zonas a partir de cartografía existente. Se aplicaron los modelos desarrollados para las distintas fechas, obteniendo cartografía con tamaño de pixel 25x25 m (Figura 3). En la capa ráster resultado, el valor de cada pixel representa el volumen forestal de esa localización. Los rangos de valores de volumen en distintos productos generados se resumen en el cuadro 2.

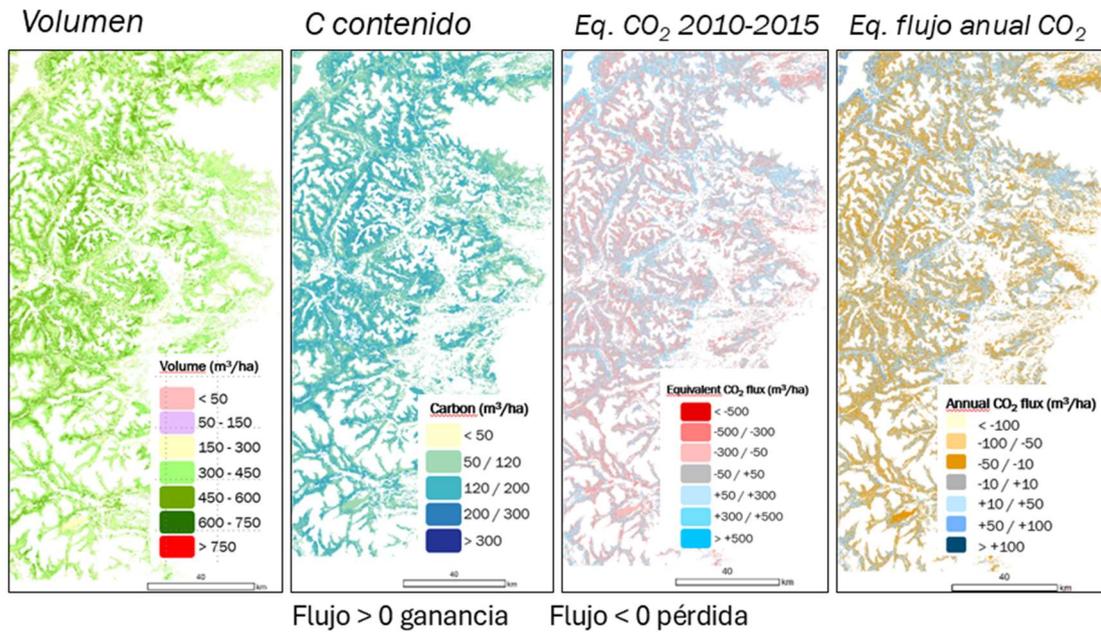


Figura 3. Ejemplo de la cartografía de variables en parte de la zona piloto de Aysén

Cuadro 2. Resumen de los modelos de volumen con algoritmo k-NN en las zonas piloto

| Modelo | Mínimo | Máximo | Media | Desv. estándar |
|-----------------|--------|---------|---------|----------------|
| Los Lagos 2015 | 12.410 | 992.743 | 317.581 | 144.470 |
| Los Lagos 2010 | 4.100 | 973.013 | 272.571 | 133.322 |
| Aysén 2015 | 7.944 | 856.305 | 343.147 | 116.842 |
| Aysén 2010 | 18.527 | 818.187 | 347.649 | 111.286 |
| Magallanes 2015 | 8.176 | 955.107 | 348.690 | 153.971 |
| Magallanes 2010 | 0.445 | 907.645 | 344.451 | 174.067 |

AGRADECIMIENTOS

Los datos ALOS PALSAR adquiridos por JAXA fueron adquiridos a través de ASF (Alaska Satellite Facility) y Google Earth Engine. Los datos de campo de inventario forestal continuo en Chile fueron facilitados por INFOR Chile.

BIBLIOGRAFIA

- [1] Breidenbach, J., Ivanovs, J., Kangas, A., Nord-Larsen, T., Nilsson, M., & Astrup, R. (2021). Improving living biomass C-stock loss estimates by combining optical satellite, airborne laser scanning, and NFI data. *Canadian Journal of Forest Research*, 51(10), 1472–1485. <https://doi.org/10.1139/cjfr-2020-0518>
- [2] Jesus, J. and Kuplich, T. (2020). Applications of SAR data to estimate forest biophysical variables in Brazil. *Cerne*, 26(1), 88-97. <https://doi.org/10.1590/01047760202026012656>

- [3] Ji, Y., Huang, J., Ju, Y., Guo, S., & Yue, C. (2020). Forest structure dependency analysis of L-band SAR backscatter. *PeerJ*, 8, e10055. <https://doi.org/10.7717/peerj.10055>
- [4] Kennedy, R. E., Ohmann, J., Gregory, M., Roberts, H., Yang, Z., Bell, D. M., Kane, V., Hughes, M. J., Cohen, W. B., Powell, S., Neeti, N., Larrue, T., Hooper, S., Kane, J., Miller, D. L., Perkins, J., Braaten, J., & Seidl, R. (2018). An empirical, integrated forest biomass monitoring system. *Environmental Research Letters*, 13(2), 025004. <https://doi.org/10.1088/1748-9326/aa9d9e>
- [5] Liu, X., Wang, R., Shi, W., Wang, X., & Yang, Y. (2024). Research on Estimation Model of Carbon Stock Based on Airborne LiDAR and Feature Screening. *Sustainability*, 16(10), Article 10. <https://doi.org/10.3390/su16104133>
- [6] Mitchard, E.T.A., Saatchi, S.S., White, L.J.T., Abernethy, K.A., Jeffery, K.J., Lewis, S.L., Collins, M., Lefsky, M.A., Leal, M.E., Woodhouse, I.H., Meir, P. (2012). Mapping tropical forest biomass with radar and spaceborne LiDAR in Lope National Park, Gabon: overcoming problems of high biomass and persistent cloud. *Biogeosciences*, 9, 179-191, <https://doi.org/10.5194/bg-9-179-2012>
- [7] Nguyen, T. H., Jones, S., Soto-Berelov, M., Haywood, A., & Hislop, S. (2018). A Comparison of Imputation Approaches for Estimating Forest Biomass Using Landsat Time-Series and Inventory Data. *Remote Sensing*, 10(11), Article 11. <https://doi.org/10.3390/rs10111825>
- [8] Novo-Fernández, A., Barrio-Anta, M., Recondo, C., Cámara-Obregón, A., & López-Sánchez, C. A. (2019). Integration of National Forest Inventory and Nationwide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-Western Spain. *Remote Sensing*, 11(14), Article 14. <https://doi.org/10.3390/rs11141693>
- [9] Pascual, A., Grau-Neira, A., Morales-Santana, E., Cereceda-Espinoza, F., Pérez-Quezada, J., Cárdenas Martínez, A., & Fuentes-Castillo, T. (2024). Old-growth mapping in Patagonia's evergreen forests must integrate GEDI data to overcome NFI data limitations and to effectively support biodiversity conservation. *Forest Ecology and Management*, 568, 122059. <https://doi.org/10.1016/j.foreco.2024.122059>
- [10] Perez-Quezada, J. F., Moncada, M., Barrales, P., Urrutia-Jalabert, R., Pfeiffer, M., Herrera, A. F., & Sagardía, R. (2023). How much carbon is stored in the terrestrial ecosystems of the Chilean Patagonia? *Austral Ecology*, 48(5), 893–903. <https://doi.org/10.1111/aec.13331>
- [11] Santi, E., Paloscia, S., Pettinato, S., Cuzzo, G., Padovano, A., Notarnicola, C., & Albinet, C. (2020). Machine-Learning Applications for the Retrieval of Forest Biomass from Airborne P-Band SAR Data. *Remote Sensing*, 12(5), Article 5. <https://doi.org/10.3390/rs12050804>
- [12] Santoro, M., & Cartus, O. (2018). Research Pathways of Forest Above-Ground Biomass Estimation Based on SAR Backscatter and Interferometric SAR Observations. *Remote Sensing*, 10(4), Article 4. <https://doi.org/10.3390/rs10040608>
- [13] Santoro, M., Cartus, O., Fransson, J. E. S., & Wegmüller, U. (2019). Complementarity of X-, C-, and L-band SAR Backscatter Observations to Retrieve Forest Stem Volume in Boreal Forest. *Remote Sensing*, 11(13), Article 13. <https://doi.org/10.3390/rs11131563>

- [14] Shimada, M., Isoguchi, O., Tadono, T., Isono, K. (2009). PALSAR radiometric and geometric calibration. *IEEE Transactions on Geosciences and Remote Sensing*, 47(12), 3915-3932. <https://doi.org/10.1109/TGRS.2009.2023909>
- [15] Tamiminia, H., Salehi, B., Mahdianpari, M., Beier, C. M., & Johnson, L. (2022). A Comparative analysis of pixel-based and object-based approaches for forest above-ground-biomass estimation using random forest model. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLVI-M-2-2022*, 191–196. ASPRS 2022 Annual Conference - 6–8 February & 21–25 March 2022, Denver, Colorado, USA & virtual. <https://doi.org/10.5194/isprs-archives-XLVI-M-2-2022-191-2022>
- [16] Torres, R., Snoeij, P., Geudtner, D., et al. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- [17] Udali, A., Lingua, E., Persson, H.J. (2021). Assessing Forest Type and Tree Species Classification Using Sentinel-1 C-Band SAR Data in Southern Sweden. *Remote Sensing* 13, Article 3237. <https://doi.org/10.3390/rs13163237>
- [18] Urbazaev, M., Thiel, C., Cremer, F., Dubayah, R., Migliavacca, M., Reichstein, M., & Schullius, C. (2018). Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. *Carbon Balance and Management*, 13(1), 5. <https://doi.org/10.1186/s13021-018-0093-5>
- [19] Yu, Y., Saatchi, S., Domke, G. M., Walters, B., Woodall, C., Ganguly, S., Li, S., Kalia, S., Park, T., Nemani, R., Hagen, S. C., & Melendy, L. (2022). Making the US national forest inventory spatially contiguous and temporally consistent. *Environmental Research Letters*, 17(6), 065002. <https://doi.org/10.1088/1748-9326/ac6b47>
- [20] Zhang, W., Zhao, L., Li, Y., Shi, J., Yan, M., & Ji, Y. (2022). Forest Above-Ground Biomass Inversion Using Optical and SAR Images Based on a Multi-Step Feature Optimized Inversion Model. *Remote Sensing*, 14(7), Article 7. <https://doi.org/10.3390/rs14071608>