



UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE CIENCIAS FORESTALES
INGENIERÍA EN CONSERVACIÓN DE RECURSOS NATURALES

**MODELACIÓN DE BIOMASA EN BOSQUE NATIVO DE *NOTHOFAGUS* DEL SUR
DE CHILE UTILIZANDO LIDAR INCORPORANDO LA PROPAGACIÓN DE
ERRORES**

Tesis presentada a la Facultad de Ciencias Forestales de la Universidad de
Concepción para optar al título profesional de Ingeniera en Conservación de
Recursos Naturales

POR: Gustavo Avendaño Staforelli
Profesor Guía: Dr. Simón Sandoval Rocha

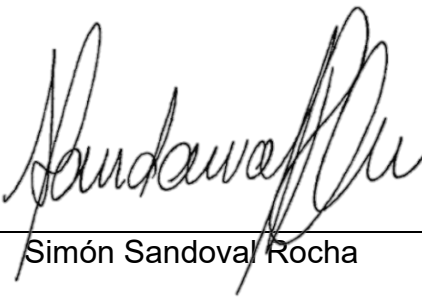
Agosto, 2025
Concepción, Chile

© 2025, Gustavo Andrés Avendaño Staforelli

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento

**MODELACIÓN DE BIOMASA EN BOSQUE NATIVO DE *NOTHOFAGUS* DEL SUR
DE CHILE UTILIZANDO LIDAR INCORPORANDO LA PROPAGACIÓN DE
ERRORES**

Profesor Guía

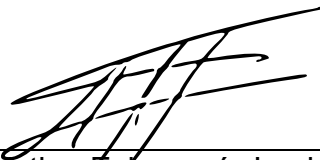


Simón Sandoval Rocha

Profesor Asistente

Ingeniero Forestal, Dr.

Profesor Co-Guía



Cristian Echeverría Leal

Profesor Titular

Ingeniero Forestal, PhD.

DEDICATORIA

Al Chicho, quien estuvo desde esos primeros días de universidad hasta los últimos días de trabajo en esta tesis, siempre entregándome la tranquilidad necesaria.

AGRADECIMIENTOS

Quiero dar mis más profundos agradecimientos a mi profesor Simón Sandoval por haber confiado en mi para guiar mi investigación. Agradecer también Estefany, la mejor coincidencia que me entregó la universidad. Por último, agradecer a mis papás y hermanos, por ser mi sostén a lo largo de todos estos años.

TABLA DE CONTENIDO

RESUMEN	viii
I. INTRODUCCIÓN	9
II. ESTADO DEL ARTE	12
2.1. Acuerdo de París y Contribuciones a Nivel Nacional (NDC)	12
2.2. Bosques como agentes para combatir el cambio climático	13
2.3. Bosque nativo en Chile: el caso del tipo forestal “Roble-Raulí-Coihue”	15
2.4. Inventarios forestales: herramienta para la estimación de variables estructurales	17
2.5. Tecnología Light Detection and Ranging (LiDAR)	18
2.6. Método Area Based Approach (ABA)	20
2.7. Estimación de la incertidumbre	21
2.8. Tamaño de muestra	22
2.9. Errores de procesos y mediciones de campo	25
2.10. Errores de geoposicionamiento y efecto borde	27
2.11. Errores en fase de modelación	29
2.12. Propagación de errores y su efecto en las estimaciones finales	31
III. CONCLUSIONES	37
IV. BIBLIOGRAFÍA	38

ÍNDICE DE ILUSTRACIONES

Figura 1. Balance de GEI (kt CO ₂ eq) por sector, serie 1990-2022.	13
Figura 2. Superficies de tipos forestales con especies de <i>Nothofagus</i> por región....	17

RESUMEN

Los bosques nativos del sur de Chile cumplen funciones ecológicas fundamentales y representan un importante reservorio de carbono, siendo uno de los pocos ecosistemas que tienen la capacidad de almacenar el CO₂ presente en la atmósfera, el principal Gas de Efecto Invernadero (GEI). Para la adecuada gestión y conservación de estos ecosistemas, es necesario contar con estimaciones confiables sobre sus características estructurales. En este contexto, la teledetección LiDAR y el enfoque Area-Based Approach (ABA) permiten estimar variables sobre toda el área de estudio, pero la mayoría de las aplicaciones no reporta de forma explícita la incertidumbre asociada, una brecha crítica en ecosistemas nativos de alta complejidad estructural como el tipo Roble–Raulí–Coihue (RORACO).

El presente estudio tiene como objetivo principal modelar variables estructurales en un bosque RORACO utilizando datos LiDAR, incorporando un análisis explícito de la propagación de errores a partir de diferentes fuentes de error. Para ello, se compararán diferentes métodos de estimación, con el fin de analizar las diferencias en las magnitudes de la incertidumbre. De esta manera, se busca generar una base metodológica reproducible que permita reportar la incertidumbre asociada a las estimaciones poblacionales realizadas a través de los inventarios forestales asistidos por tecnología LiDAR, en especial en ecosistemas nativos de alta complejidad estructural.

I. INTRODUCCIÓN

Los ecosistemas nativos tienen un alto valor biológico, social y económico, proporcionando diferentes beneficios para el ser humano. Entre ellos está el suministro de agua, provisión de alimentos y aire limpio, control de inundaciones, abastecimiento de madera y son reservorios del carbono atmosférico (Bahamóndez et al., 2020; McDonald et al., 2016). Esta capacidad de almacenar el carbono presente en la atmosfera es una solución basada en la naturaleza que contribuye a mitigar los efectos del cambio climático (Müller-Using et al., 2021), por lo que conocer los estados actuales de los bosques es fundamental. Frente a los retos ecológicos actuales, contar con información precisa y espacialmente detallada sobre la estructura de estos bosques se ha vuelto una prioridad para su conservación y manejo sostenible (Zeng et al., 2015).

Tradicionalmente, la caracterización estructural de los rodales forestales se ha realizado mediante inventarios de terreno, utilizando parcelas de muestreo establecidas bajo diseños probabilísticos (Gregoire, 1998; Thompson, 2012). Sin embargo, estos métodos requieren alta inversión en tiempo y recursos, especialmente en áreas extensas o de difícil acceso (Goodbody et al., 2017). Como alternativa, el uso de sensores remotos ha permitido mejorar la eficiencia de los inventarios forestales, destacando la tecnología LiDAR (Light Detection and Ranging) por su capacidad de representar tridimensionalmente la estructura del dosel forestal con alta resolución espacial (Lefsky et al., 2002; Vauhkonen et al., 2014).

Uno de los enfoques más utilizados para la estimación de variables estructurales mediante datos LiDAR es el Area Based Approach (ABA), el cual integra información de terreno y métricas derivadas de la nube de puntos para construir modelos predictivos (White et al., 2013). Si bien ABA ha mostrado buenos resultados en la estimación de atributos como altura del dosel, volumen o biomasa (Næsset, 2002; Bouvier et al., 2015), en la mayoría de los estudios no se ha incorporado de forma sistemática la propagación de errores provenientes de cada etapa del proceso de estimación, lo que limita la interpretación de la incertidumbre asociada a los resultados finales (Ulvdal et al., 2025).

Los errores en inventarios asistidos por sensores remotos pueden originarse en diversas fases: desde la medición en terreno (Wertz et al., 2025), el ajuste de ecuaciones alométricas (Huang et al., 1992), el geoposicionamiento de parcelas (Gobakken & Næsset, 2009), hasta la selección del modelo de predicción (Cosenza et al., 2024). Cuando estas fuentes de error se acumulan sin un tratamiento adecuado, pueden sesgar las estimaciones o reducir su confiabilidad. En este contexto, la propagación de errores se presenta como una herramienta fundamental para cuantificar de forma realista la incertidumbre total del proceso (Molto et al., 2013; Sandoval & Bustamante-Ortega, 2020).

Si bien existen antecedentes sobre la estimación de incertidumbre en bosques templados o tropicales (Chave et al., 2003; Arias-Rodil et al., 2017), son escasos los estudios que han abordado este problema en bosques nativos del sur de Chile. Dada la alta variabilidad estructural de estos ecosistemas (Moreno et al.,

2018), evaluar el efecto de la propagación de errores en la estimación de variables estructurales cobra especial relevancia.

Esta investigación tiene por objetivo evaluar el efecto de la propagación de errores provenientes de distintos procesos secuenciales de estimación —como mediciones de campo, ajuste de modelos alométricos y generación de métricas LiDAR— sobre la incertidumbre y las estimaciones poblacionales de variables estructurales del bosque nativo mediante el método ABA. Para ello, se integrarán y modelarán las principales fuentes de error en cada fase del proceso, con el fin de analizar cómo estas se propagan y afectan la media y la varianza de las estimaciones finales.

II. ESTADO DEL ARTE

2.1. Acuerdo de París y Contribuciones a Nivel Nacional (NDC)

El cambio climático constituye una emergencia que exige soluciones coordinadas para que los países puedan avanzar hacia una economía con bajas emisiones de carbono. Para ello, en el año 2015, en la 21ª Conferencia de las Naciones Unidas sobre el Cambio Climático (COP21) se firmó el Acuerdo de París (AP), que tiene como uno de sus principales objetivos a largo plazo “reducir sustancialmente las emisiones de gases de efecto invernadero para limitar el aumento de la temperatura global en este siglo a 2 °C y esforzarse para limitar este aumento a incluso más de tan solo el 1,5 °”. Para lograrlo, los países que firmaron el AP deben enviar un plan nacional actualizado de acción climática cada cinco años, conocido como Contribución Determinada a Nivel Nacional (NDC).

En Chile, con el fin de alcanzar las metas establecidas en el AP, se promulgó en el año 2022 la Ley Marco de Cambio Climático (LMCC), que tiene como uno de sus principales objetivos el transitar hacia un desarrollo bajo en emisiones hasta alcanzar y mantener la carbono neutralidad a más tardar en el año 2050. En esa línea, según cifras del Sistema Nacional de Inventario de emisiones de Gases de Efecto Invernadero (SNI), en el año 2022 las emisiones de GEI totales del país contabilizaron 111.049 kt CO₂ eq, incrementándose en un 135 % desde 1990 y en un 7,1 % desde 2020. Dentro de los sectores que influyen en el balance de

los GEI, el Uso de la tierra, cambio de uso de la tierra y silvicultura (UTCUTS) es el único que consistentemente absorbe CO₂ en el país, lo que lo convierte en el más relevante por su potencial de mitigación, tal como se puede observar en la figura 1, donde el único año en que el balance fue positivo fue el 2017, debido a los incendios forestales ocurridos.

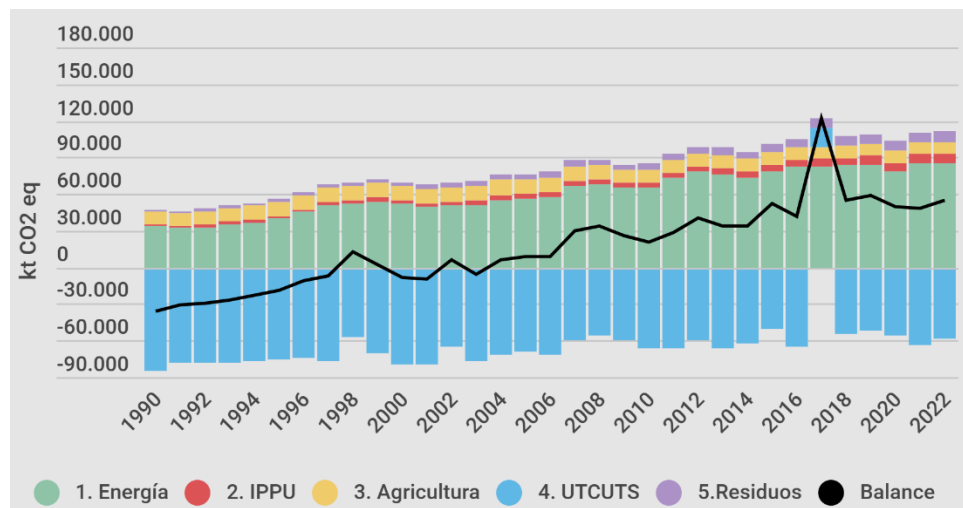


Figura 1. Balance de GEI (kt CO₂ eq) por sector, serie 1990-2022- Fuente: IGNEI de Chile.

2.2. Bosques como agentes para combatir el cambio climático

Los bosques son capaces de retener y almacenar el carbono presente en la atmosfera (como dióxido de carbono) durante períodos prolongados, además de proporcionar notable enfriamiento mundial a través de la evapotranspiración y de su estructura física y química. Además de su rol de mitigación, los bosques son fundamentales para la adaptación y la resiliencia ante el cambio climático, ya que poseen la capacidad de regular las precipitaciones y estabilizar las condiciones climáticas a nivel local, contribuyendo así a reducir la intensidad de eventos

meteorológicos (FAO, 2024). Así, soluciones basadas en la naturaleza, como el almacenamiento de carbono en los árboles contribuye a mitigar los efectos del cambio climático (Müller-Using et al., 2021).

Cuantificar y caracterizar estos recursos es fundamental para generar información base con el objeto de contribuir para la toma de decisiones, la planificación ambiental y la definición de políticas de gestión para la conservación de estos recursos (CONAF, 2024). De esta manera, las evaluaciones del estado del bosque, como la cantidad de biomasa o el carbono almacenado, son herramientas fundamentales para abordar los problemas relacionados al cambio climático y las emisiones de CO₂ (Zeng et al., 2015).

La madera es capaz de retener y almacenar, durante períodos prolongados, el carbono presente en la atmósfera como dióxido de carbono; este gas es uno de los principales responsables del calentamiento global, de modo que la madera contribuye entonces, a mitigar los efectos del cambio climático (Müller-Using et al., 2021). De esta manera, las evaluaciones como los cambios en las existencias de biomasa son herramientas integrales para abordar los problemas relacionados al cambio climático y las emisiones de CO₂ (Zeng et al., 2015).

Cuantificar y caracterizar estos recursos es fundamental para generar información base con el objeto de contribuir para la toma de decisiones, la planificación ambiental y la definición de políticas de gestión para la conservación de estos recursos (CONAF, 2024). De esta manera, las evaluaciones del estado del bosque, como la cantidad de biomasa o el carbono almacenado, son

herramientas fundamentales para abordar los problemas relacionados al cambio climático y las emisiones de CO₂ (Zeng et al., 2015).

2.3. Bosque nativo en Chile: el caso del tipo forestal “Roble-Raulí-Coihue”

En Chile, según la última actualización del Catastro Nacional de Recursos Vegetacionales elaborado por CONAF publicado el 2024, los bosques nativos cubren el 19,5% de la superficie nacional con 14,7 millones de hectáreas. Dentro de ellos, el bosque nativo con dominancia de especies del género *Nothofagus* concentra la mayor superficie en el país, alcanzando casi 8,4 millones de hectáreas (57,6%) (CONAF, 2024). Los árboles del género *Nothofagus* desempeñan un papel fundamental en la configuración de la estructura de los bosques templados y subantárticos, creando hábitats para numerosas especies de flora y fauna, además de tener la capacidad de almacenar cantidades significativas de carbono (Echeverría, 2024).

Dentro de los tipos forestales se encuentra el de Roble-Raulí-Coihue (RO-RA-CO), con 1,7 millones de hectáreas de superficie, extendiéndose desde la región de O'Higgins hasta la región de Los Lagos. El tipo de bosque secundario RO-RA-CO es un ecosistema complejo y se encuentra en un gradiente de vegetación que abarca amplios rangos geográficos tanto en latitud como en altitud, extendiéndose en Chile desde los 36°S hasta los 41°S de latitud, aproximadamente desde la costa del Pacífico hasta la cordillera de los Andes

(Moreno et al., 2018). Dentro de los servicios ecosistémicos que proveen estos ecosistemas se encuentran la provisión de madera, provisión de leña, provisión de productos forestales no madereros (PFNM), provisión de agua y regulación del ciclo hídrico, belleza escénica y captura de carbono (Müller-Using, 2020). Respecto a este último servicio, a partir de la información de crecimiento del Inventario Forestal Nacional de INFOR, se estima que los renovales de RO-RA-CO pueden secuestrar entre 7,7 y 14,3 tCO₂ e/ha/ año en biomasa aérea y radicular, dependiendo de la etapa de crecimiento en la que se encuentren (Ministerio del Medio Ambiente, 2019), y que aplicando actividades silvícolas asociadas a la recuperación de estos bosques degradados como limpia, cercado y plantación suplementaria, la captura alcanza valores aun mayores. Para estos casos se ha estimado una captura neta de carbono para la biomasa aérea y radicular de 17,1 tCO₂ e/ha para un horizonte de 20 años (Bahamóndez et al., 2010; INFOR-INIA, 2014).




Figura 2. Superficies de tipos forestales con especies de *Nothofagus* por región. Fuente: Catastro de los Recursos Vegetacionales y Uso de la Tierra de Chile CONAF, 2024.

2.4. Inventarios forestales: herramienta para la estimación de variables estructurales

El inventario forestal es la principal herramienta para la evaluación de los recursos forestales, y sus resultados se utilizan para definir el manejo forestal ya que se considera fiable y adecuada para los fines previstos (Zeng et al., 2015; Zhang et al., 2016). Para generar estimadores confiables de las variables de la condición del rodal, es fundamental minimizar los errores de medición en la fase de captura de datos en terreno. Esta fase se ve afectada por la intensidad de muestreo, la condición del bosque y a la accesibilidad a los sitios; esta última implica un aumento en los costos operativos y en el tiempo de procesamiento de la información (Goodbody et al., 2017). Otra limitación asociada a los inventarios tradicionales es que a medida que aumenta la superficie del área de estudio y/o

la variabilidad de la población, la intensidad de muestreo requerida para obtener estimaciones confiables debe ser cada vez mayor, si el objetivo además es controlar el error muestral.

En respuesta a algunas de estas limitaciones, las tecnologías de teledetección desde sensoramiento remoto han surgido como alternativa para apoyar la realización de inventarios forestales. Tienen la capacidad de proporcionar información precisa y espacialmente actualizada, lo que permite caracterizar la estructura del bosque y medir distintas variables de un rodal para la elaboración de inventarios forestales (McRoberts et al., 2018; Puliti et al., 2020). Dentro de estas tecnologías, LiDAR (Light Detection and Ranging) se ha convertido en una de las tecnologías de teledetección más prometedoras para proporcionar datos para la investigación y las aplicaciones operacionales en una amplia gama de disciplinas relacionadas con la ordenación de los ecosistemas forestales (Vauhkonen et al., 2014).

2.5. Tecnología Light Detection and Ranging (LiDAR)

Herramientas basadas en sensoramiento remoto se han utilizado para complementar las estimaciones de parámetros estructurales de los bosques. Una de las más utilizadas es LiDAR, ya que puede proporcionar características tridimensionales detalladas de las estructuras del dosel forestal (Harding et al., 2001; Lefsky et al., 2002; Næsset y Gobakken, 2008). El uso de LiDAR para proporcionar datos de los ecosistemas forestales ha experimentado un enorme crecimiento desde mediados de la década de 1990 al ser un medio rentable para

obtener datos con alta resolución espacial y alta precisión posicional (Vauhkonen et al., 2014). Una de las maneras de adquirir los datos LiDAR es a través de un sistema de Escaneo Laser Aerotransportado (ALS), el cual distribuye la luz emitida a lo largo de la trayectoria de vuelo de la aeronave.

Con la información adquirida a través del vuelo se genera una nube de puntos, con la cual se pueden realizar estimaciones de variables a nivel de árbol individual y rodal. Para ello, se utilizan modelos previamente calibrados, los cuales son funciones matemáticas que relacionan las variables de rodal medidas en terreno con las métricas obtenidas de la nube de puntos LiDAR (Sandoval y Bustamante-Ortega, 2020). Ortiz-Reyes et al. (2019) dividieron las métricas LiDAR más utilizadas para la distribución de los elementos de la vegetación en tres grupos: los percentiles de distribución de las alturas, las métricas de densidad y las estadísticas que describen la distribución de las alturas en una parcela o área determinada.

Una de las principales ventajas que tiene el inventario LiDAR en comparación a los inventarios tradicionales es que permiten identificar y visualizar la variabilidad espacial del rodal. Por ejemplo, Næsset (2002) evaluó la precisión en la estimación de la altura media en rodales forestales a partir de la incorporación de variables auxiliares LiDAR e informó que entre el 82 y el 95% de la variabilidad de la altura media medida en terreno podría explicarse mediante modelos que utilizan información LiDAR. En otro estudio, Drake et al. (2002) informaron que un 53% de la variabilidad de biomasa aérea (AGB) estimada a partir de

información de terreno de un bosque tropical puede ser explicada con información auxiliar LiDAR.

2.6. Método Area Based Approach (ABA)

Para la estimación de estas variables a nivel de rodal a partir de información LiDAR, el método más utilizado es el método de masa o *Area Based Approach* (ABA). Este método genera estimaciones de variables de rodal para cada unidad discretizada del bosque, definido por píxeles de tamaño fijo. En cada píxel que compone la población, se genera una estimación de variables del bosque utilizando modelos parametrizados en una fase previa, los cuales usan métricas LiDAR como variables predictoras.

White et al. (2013) describieron el método ABA en dos pasos principales. En primer lugar, se adquieren los datos LiDAR de toda el área de interés y se registran mediciones en terreno a través de parcelas de muestreo. Luego, la nube de puntos se recorta con los polígonos de cada parcela, para así generar modelos predictivos, los cuales se construyen utilizando los atributos de la parcela como variable de respuesta y las métricas derivadas de ALS como predictores. El segundo paso consiste en aplicar los modelos generados en el paso uno a toda el área de estudio para generar estimaciones de atributos específicos a nivel del rodal completo. Como resultado final, se obtienen predicciones a nivel de píxel, cuya área frecuentemente es consistente con el área de la parcela medida en

terreno, generándose así una cuadrícula compuesta por píxeles que son el resultado de la estimación para el atributo de interés.

Existen diferentes estudios que han utilizado el método ABA para estimar variables a nivel de rodal, obteniendo buenos resultados. Por ejemplo, López y Sandoval (2023) obtuvieron un RMSE de 23,6% en la estimación de la densidad de rodal de *Pinus radiata* a partir de la métrica del percentil 95. Kankare et al. (2013) mapearon la biomasa de los bosques boreales de Finlandia obteniendo un RMSE de 24,9%. Bouvier et al. (2015) realizaron estimaciones de diferentes atributos para tres tipos de bosques diferentes: bosque de coníferas (monoespecífico), bosque caducifolio y bosque montañoso. Ellos generaron cuatro métricas predictoras, obteniendo resultados que varían entre los tres sitios diferentes. Por ejemplo, en el cálculo de biomasa aérea (AGB), obtuvieron una desviación estándar relativa (RSD) de 12,86% para coníferas, 18,1% para caducifolias sin hojas y 19,4% con hojas, y 22,3% para el sitio de estudio montañoso. Este estudio evidenció como varía el error entre bosques homogéneos (coníferas) y bosques más heterogéneos (caducifolio y montañoso).

2.7. Estimación de la incertidumbre

La estimación de la incertidumbre en inventarios forestales asistidos por sensores remotos requiere considerar tanto los errores provenientes de los datos de teledetección como aquellos originados en las mediciones de terreno. Según

Ulvdal et al. (2025), los errores aleatorios y sistemáticos en predicciones derivadas de sensores remotos pueden afectar significativamente la planificación forestal, especialmente cuando no se cuantifican adecuadamente. Un obstáculo para la estimación de variables forestales mediante sensoramiento remoto es la calidad de los datos, entendida como la exactitud y precisión con que estos representan las características del bosque (Fassnacht et al., 2024). Sin embargo, estas fuentes de error no se limitan al sensor satelital o LiDAR, sino que también se generan en las mediciones de campo, el ajuste de ecuaciones alométricas y la calibración de modelos estadísticos. Diversos estudios han documentado la presencia de incertidumbre en los inventarios forestales tradicionales (Eid y Næsset, 1998; Jurjević et al., 2020; Luoma et al., 2017; Wang et al., 2019) y en el uso de fotointerpretación aérea (Eid y Næsset, 1998; Tompalski et al., 2021). En el caso particular de las estimaciones derivadas de información LiDAR, las fuentes de error que pueden afectar los resultados finales son múltiples, incluyendo errores asociados a las mediciones en terreno utilizadas para la calibración, al tamaño de la muestra, al establecimiento de las parcelas, o a su geoposicionamiento. A continuación, se describen las principales fuentes de error que pueden incidir en la estimación de variables estructurales a nivel de rodal utilizando información LiDAR.

2.8. Tamaño de muestra

El tamaño de la muestra poblacional tiene impacto en la precisión de las estimaciones realizadas a nivel de rodal. Como regla general, mientras más grande sea el tamaño de la muestra, teóricamente mejor será el entrenamiento o la parametrización del modelo ya que representa mejor la variabilidad poblacional (Fassnacht et al., 2018; Hosseini et al., 2021; Saarela et al., 2015; Strunk et al., 2012).

Los inventarios forestales basados en la teledetección requieren una cierta cantidad de parcelas de muestreo en terreno, que sirven como datos de referencia utilizados para la calibración del modelo y/o como conjunto de datos de validación para la evaluación de la precisión de las variables modeladas (Stereńczak et al., 2018). En los enfoques basados en el área (ABA), tanto el número como el tamaño de las parcelas desempeñan un papel crucial en el tiempo y los costos que se invierten en la recopilación de los datos de campo. Por lo tanto, es deseable identificar un número y tamaño óptimos de parcelas de campo (Hosseini et al., 2021).

Para evaluar la precisión en las estimaciones de diferentes variables forestales utilizando diferentes tamaños muestrales, Strunk et al. (2012) hicieron 5000 simulaciones para cada una de las combinaciones del tamaño de muestra entre 15 y 105 parcelas de 809 m² en un bosque de coníferas en Estados Unidos. El efecto del tamaño de la muestra fue leve para las muestras con 45 o más observaciones. Con menos de 45 observaciones, la mediana de la distribución de simulación de los modelos RMSE y la amplitud de las distribuciones de

simulación aumentaron en menos del 1% al disminuir de 55 a 45 observaciones. Mientras que disminuir de 25 a 15 observaciones, la RMSE aumentó a un 7%.

Fassnacht et al. (2018) estimaron la biomasa aérea del bosque de manera asistida utilizando información LiDAR, considerando también la relación con el tamaño de la muestra. Los autores simularon datos realistas de altura del dosel y tipo de cobertura mediante la combinación del simulador de bosque SILVA (Biber et al., 2000; Pretzsch et al., 2002) con nubes de puntos reales, con el objetivo de evaluar los beneficios de establecer parcelas de muestreo grandes. Los resultados confirmaron que el aumento del tamaño de la parcela con un tamaño de muestra constante, mejoraba la precisión del modelo. Sin embargo, los resultados sugieren que manteniendo el área total muestreada constante (es decir, la suma de las superficies de las parcelas) y cambiando los tamaños de las parcelas, las diferencias de precisión entre parcelas pequeñas y grandes tendía a desaparecer.

En un estudio más reciente, Hosseini et al. (2021) quisieron replicar lo hecho por Frasnacht et al. (2018), pero esta vez con datos reales y utilizando imágenes satelitales de muy alta resolución (VHR). El estudio consistió en la medición de 311 ubicaciones, donde en cada una se establecieron parcelas concéntricas de 100, 300 y 500 m², para así evaluar la como afectaba tanto el número de parcelas como el tamaño de estas, en las estimaciones biomasa aérea de plantaciones forestales en Irán. Sus resultados confirmaron la necesidad de un tamaño de muestra lo suficientemente grande para poder obtener estimaciones precisas, concluyendo además que el tamaño de las parcelas no sugiere ninguna ventaja

clara. Por ejemplo, al aumentar de 24 a 192 muestras (en promedio para los tres tamaños de parcelas), el desempeño mejoró de $r = 0,61$ a $0,79$. Además, indicaron que un tamaño de muestra mayor con parcelas más pequeñas puede ser más ventajoso en comparación con un menor tamaño de muestra con parcelas grandes, siempre que el área total de muestreo sea limitada. Estos resultados fueron también de la mano con lo obtenido en estudios previos (Sterénczak et al. 2018; Fassnacht et al.,2018), quienes también informaron que aumentar el tamaño de la muestra es más efectivo para mejorar el rendimiento del modelo que aumentar el tamaño de las parcelas.

2.9. Errores de procesos y mediciones de campo

El proceso de caracterización estructural de un rodal comienza con el levantamiento de datos en terreno. Dentro de las unidades muestrales (parcelas) se realizan mediciones de diferentes variables de interés a nivel de árbol, como la altura total (H), el diámetro a la altura del pecho (DAP), además de registrar la especie de cada individuo. Estas mediciones están sujetas a errores, tanto por las limitaciones de los instrumentos como por el nivel de experiencia del operador. En un estudio reciente, Wertz et al. (2025) evaluaron la precisión y exactitud de la medición de la altura de los árboles desde el suelo, considerando dos niveles de experiencia del usuario (principiante y experto) y comparando dos hipómetros de uso frecuente: uno analógico (Suunto) y otro ultrasónico (Vertex).

Los resultados mostraron que los usuarios principiantes fueron entre 2,5 y 3,5 veces menos precisos que los usuarios con experiencia, dependiendo del hipsómetro utilizado. Además, se observó una subestimación promedio del -1,7 % en las alturas registradas por los operadores novatos.

Muchos modelos de crecimiento y rendimiento de variables como volumen o biomasa requieren la altura y el diámetro como variables básicas de entrada, con la totalidad o parte de las alturas de los árboles predichas a partir de los diámetros medidos en terreno (Huang et al., 1992). La medición de la altura de cada individuo resulta a veces difícil y lenta, lo que implica mayores costos operacionales. Esta dificultad se ve acrecentada a medida que el árbol es de mayor altura, ya que, dependiendo de la visibilidad, la distinción del ápice puede volverse más compleja, condicionando la precisión de la medición. Dadas estas complicaciones, la estimación de las alturas suele realizarse a través de modelos que utilizan como variable predictora el DAP de cada árbol. Así, los errores producidos en las fases de medición en terreno y modelación son un factor que influye directamente en la estimación de variables de rodal a partir del método ABA.

A pesar de estos errores asociados a las mediciones, la mayoría de los estudios no los considera. Así, cuando se usan esos modelos incorporando los errores de medición, las estimaciones podrían estar sesgadas (Gertner y Dzialowy, 1984).

2.10. Errores de geoposicionamiento y efecto borde

En los inventarios forestales, las parcelas de muestreo generalmente son georreferenciadas utilizando Sistemas de Posicionamiento Global (GPS). Los GPS son herramientas basadas en satélites para determinar la ubicación de puntos sobre la superficie de la Tierra y su precisión depende de los instrumentos, los usuarios, recepción de satélites, factores atmosféricos, ambientales y locales como lo son el tipo de dosel de los bosques (Johnson y Barton, 2004).

Gobakken y Næsset (2009) evaluaron el impacto de errores de posicionamiento de las parcelas de terreno sobre métricas derivadas de nubes de puntos LiDAR y sobre algunas variables de rodal de interés (área basal, volumen y altura media), en bosques boreales de Noruega. Para ello, alteraron aleatoriamente las coordenadas de 132 parcelas concéntricas de 200 m² combinadas con áreas de 300 o 400 m², aplicando desplazamientos horizontales de entre 0,5 y 20 metros. Cada nivel de error fue simulado 500 veces para ambos tamaños de parcela utilizando simulaciones de Monte Carlo. Los resultados mostraron que las mayores diferencias en las métricas relacionadas a las alturas se encontraron en el coeficiente de variación de la distribución de alturas de la copa (h_{cv}). Por otro lado, en la estimación de las variables de rodal, la influencia del error de posición de las parcelas fue mayor en el caso del área basal y el volumen. Por ejemplo, para parcelas pequeñas, incluso con errores de posición de 0,5 m se produjeron valores de desviación estándar de más del 22,8% en las estimaciones de área

basal. En el caso de las estimaciones de volumen, los mayores errores se produjeron en parcelas pequeñas, donde los valores de desviación estándar alcanzaron un 27,8% con un error de posición de 0,5 m. Por otro lado, las estimaciones con parcelas de mayor tamaño obtuvieron resultados más precisos, como una desviación estándar máxima de 16,8% en el caso del volumen estimado, considerando un error de posición de 5 m. De esta manera, los autores concluyeron que en bosques maduros es importante tener parcelas grandes y una georreferenciación precisa para obtener estimaciones confiables.

El error del geoposicionamiento también afecta en la fase de recolección de los datos LIDAR. Las coordenadas (x, y, z) de cada uno de los retornos de la nube de puntos del sensor también están sujetas a errores de posición, pero la magnitud de estos errores generalmente se considera menor (<0,5 m en el dominio horizontal) en comparación con los datos de campo y otros tipos de datos de teledetección (Gatziolis y Andersen, 2008). A pesar de ello, los errores tanto del GPS como de los datos LiDAR, pueden dar como resultado una superposición espacial imprecisa entre ambas fuentes de información, lo cual puede afectar negativamente la fase de modelación, generando ecuaciones de estimación sesgadas (Gobakken y Næsset, 2009; Hernández-Stefanoni et al., 2018).

La existencia de errores de geoposicionamiento tiene implicancias directas sobre los árboles ubicados en los bordes de las parcelas. Individuos que se encuentran fuera de la parcela pueden proyectar parte de sus copas dentro de la unidad muestral, y viceversa. El tamaño de las parcelas puede amortiguar o expandir el impacto del efecto borde, donde aquellas parcelas que poseen una relación

perímetro-área mayor producirán, en teoría, métricas LiDAR que son menos precisas y exactas, debido a la inclusión de un error de medición inducido por el efecto borde de la parcela sustancialmente mayor (Frazer et al., 2011).

2.11. Errores en fase de modelación.

La fase de modelación constituye un componente fundamental en la estimación de variables estructurales a partir de datos LiDAR mediante el método ABA. Las estrategias más comunes se agrupan en dos principales categorías: modelos paramétricos (lineales y no lineales) y modelos no paramétricos (árboles de decisión, Support Vector Machine, k-Nearest Neighbors, Random Forest, Redes Neuronales Artificiales, entre otros).

Los modelos paramétricos suelen ser los más utilizados dada su interpretación simple y capacidad de extrapolación fuera del rango de los datos de muestra usados para construir los modelos. Sin embargo, una desventaja de estos modelos es que necesitan satisfacer los supuestos básicos de la regresión para poder generar estimaciones consistentes e insesgadas, como homocedasticidad y normalidad (White et al., 2017). Otra limitación de los modelos paramétricos es que se ven limitados a utilizar solo algunas métricas LiDAR, ya que la mayoría de ellas se relacionan entre sí, generando problemas de multicolinealidad.

En contraste, los modelos no-paramétricos no están condicionados a supuestos estadísticos, lo que permite incorporar todas las variables y/o métricas obtenidas

desde la nube de puntos LiDAR. No obstante, los modelos no-paramétricos pueden tener algunas limitaciones al requerir de una base de datos suficientemente grande, y en el caso de las estimaciones LiDAR, se necesita cubrir la variabilidad de las características del bosque con relación a la superficie del terreno. De esta manera al necesitar de una mayor cantidad de datos con el propósito de disminuir el sesgo en las predicciones, su uso puede considerarse económicamente más costoso (Salas et al., 2010).

Históricamente, los primeros estudios que aplicaron el método ABA utilizaron principalmente modelos paramétricos. Posteriormente, comenzaron a incorporarse enfoques no paramétricos. Penner et al. (2013) compararon la precisión tanto de modelos paramétricos como no-paramétricos para la estimación de diferentes atributos forestales a partir de datos LiDAR aéreos. Con los resultados obtenidos, determinaron que las predicciones realizadas con modelos paramétricos mejoraban mediante la estratificación del bosque. Por el contrario, el tipo de bosque no fue un predictor importante para las predicciones con los modelos no-paramétricos.

Otro factor para considerar en la fase de modelación es el sobreajuste (overfitting), el cual consiste en que los modelos pueden realizar buenas predicciones para los datos de la muestra, pero deficientes para datos que no participaron en la muestra. El efecto del sobreajuste puede ser especialmente problemático en los intentos de predecir para una población diferente (área del bosque no cubierta por ninguna parcela de muestreo). En este sentido, Cosenza et al. (2024) evaluaron cómo el sobreajuste en modelos predictivos afectaba las

estimaciones de volumen cuando se utilizan datos LiDAR y Sentinel-2. Los autores compararon modelos con distintos niveles de complejidad, incluyendo regresiones lineales, k-nearest neighbors (k-NN), Random Forest y redes neuronales, aplicados a dos áreas de bosque boreal en Finlandia. Los resultados mostraron que, aunque los modelos más complejos, como k-NN y redes neuronales, presentaron mejor ajuste interno (es decir, menor error al predecir sobre los mismos datos con los que fueron entrenados), su desempeño en datos externos o independientes (validación externa) fue considerablemente peor. Por su parte, los modelos ajustados con datos de una muestra externa generaron estimaciones insesgadas, incluso si estaban sobreajustados. Finalmente, los autores concluyeron que, para evitar sesgos, es preferible utilizar modelos externos o internos parsimoniosos (2–5 predictores), especialmente cuando el tamaño de muestra es limitado. Propagación de errores y su efecto en las estimaciones finales.

2.12. Propagación de errores y su efecto en las estimaciones finales

Como se mencionó anteriormente, existen diferentes fuentes de error que se generan al momento de realizar las estimaciones de variables a nivel de rodal. Estos errores de procesos son consecutivos y se transmiten secuencialmente hasta la última fase de estimación, produciendo un aumento del error en la estimación del total poblacional. La propagación de errores se asocia con la obtención de nuevos resultados a partir de un cálculo con las cantidades medidas

y su respectivo error (Medina, 2017). Para obtener estos nuevos resultados, Fantner (2013) define dos maneras para estimar la propagación de errores. Por un lado, la versión simplificada, que considera la situación más pesimista, sumando las incertidumbres individuales. Esto permite obtener un límite seguro de la incertidumbre, pero a veces se busca ser más restrictivos con las respuestas. Para ello, se emplea el tratamiento estadístico adecuado para la propagación de errores, utilizando la desviación estándar para calcular la incertidumbre resultante.

Existen algunos estudios en el área forestal en donde se ha estimado la propagación de errores, principalmente en la estimación final de biomasa y volumen (Arias-Rodil et al., 2017; Chave et al., 2003; Molto et al., 2013). Chave et al. (2004) estudiaron la propagación de errores en el cálculo de biomasa en un bosque tropical de Panamá. Para ello, consideraron cuatro fuentes de error: (i) errores de medición en árboles (diámetro, altura y densidad de la madera); (ii) incertidumbre del modelo alométrico que relaciona el AGB con otras dimensiones del árbol; (iii) incertidumbre de muestreo asociada con el tamaño de la parcela de estudio; iv) la representatividad de una red de pequeñas parcelas a escala de paisaje. Para la parte de medición, primero propagaron la varianza del diámetro, altura y densidad a la AGB de cada árbol mediante expansión de Taylor, obteniendo una varianza individual $var(\widehat{AGB}_i)$ por árbol. Luego, para pasar de árbol a parcela, sumaron las AGB de cada árbol y sus respectivas varianzas. Finalmente, al estandarizar por hectárea, dividieron la AGB de parcela por el área

a de la unidad muestral y la varianza por a^2 . Por otro lado, la incertidumbre del modelo alométrico se evaluó por separado, comparando ecuaciones y aplicando rarefacción (remuestreo con distintos tamaños de calibración del modelo) para cuantificar cómo el número de árboles usados en el ajuste afecta la incertidumbre del modelo. Luego, para evaluar el error asociado al tamaño muestral (considerando el tamaño de las parcelas), utilizaron una parcela permanente de 50 ha, lo que permitió simular subparcelas de distintos tamaños dentro de ella, obteniendo, por ejemplo, que para parcelas de 0,25 ha el error es de aproximadamente 10% respecto al promedio. Para evaluar la última fuente de error (representatividad a escala de paisaje), evaluaron la dispersión de AGB entre parcelas independientes distribuidas en el paisaje (red de parcelas de 1 ha), lo cual permitió capturar los gradientes ambientales y la heterogeneidad a lo largo del paisaje. Al estimar un promedio con k parcelas, la incertidumbre de representatividad se cuantificó como el error estándar del promedio entre parcelas. Como resultados finales, los autores obtuvieron para un área total muestreada de 5 ha una incertidumbre acumulada en la estimación de AGB de aproximadamente el 20% de la media, con solo una pequeña fracción debido al error de medición (suponiendo una medición no sesgada), el 10% debido al error del modelo alométrico y el 10% restante debido al error de muestreo. Con parcelas más grandes, los autores concluyeron que se puede reducir la incertidumbre de muestreo, pero no la incertidumbre alométrica.

Molto et al. (2013) estudiaron la propagación de errores en la estimación de biomasa aérea (AGB) de un bosque tropical, esta vez en Guyana Francesa. En esta investigación se realizó la estimación final de AGB considerando los errores que se producían en los submodelos de altura (calculada a partir del DAP), de densidad básica de la madera (calculada a partir de información taxonómica de cada especie) y de AGB a nivel de árbol (calculada a partir del DAP, altura y densidad básica de la madera). Como resultado final, se obtuvo que, para una parcela en particular, su AGB teniendo en cuenta todas las fuentes de error, fue de 451 Mg ha^{-1} . El intervalo bayesiano de confianza del 95% alrededor de esta estimación tuvo un rango de 20 Mg ha^{-1} ($\pm 2.2\%$). Este resultado se comparó considerando el error generado por cada uno de los submodelos de manera independiente, para conocer cuál fue la fuente de error que más contribuyó a la incertidumbre final. Al considerar los submodelos de altura y de densidad específica de la madera, los intervalos de confianza en la estimación final de AGB no cambiaron significativamente. Por el contrario, cuando solo se consideró como determinista el submodelo de AGB, el intervalo de confianza fue más estrecho: 6 Mg ha^{-1} . Por lo tanto, el submodelo AGB fue el que aportó la mayor parte de la incertidumbre en la estimación de AGB.

En otra investigación, Arias-Rodil et al. (2017) determinaron como los errores en la medición de la altura total de cada individuo (h) y sus diámetros superiores (diámetro a la mitad de la altura total, d_u) incidían en las estimaciones finales de volumen a nivel de árbol en plantaciones de pino. Para ello introdujeron errores

simulados (con coeficientes de variación del 1 al 10%) en la altura total y en el diámetro superior usando simulación de Monte Carlo (1000 repeticiones por combinación). Al simular un coeficiente de variación (CV) de 10% en las alturas, el RMSE de los modelos de volumen aumentaron hasta un 60%. Por otro lado, al simular CV de 10% para el d_u , hubo una sobreestimación del volumen de hasta un 8,8% cuando el error fue positivo, mientras que cuando el error era negativo, se generaron subestimaciones de hasta un 7,8%.

Sandoval y Bustamante-Ortega (2020) determinaron como el error en la modelación usando como predictores métricas LiDAR, se propagaba en la estimación del volumen total de diferentes predios utilizando un método de remuestreo (bootstrap-pairs). Los autores compararon la incertidumbre en los inventarios forestales que utilizan información auxiliar LiDAR, considerando la heterocedasticidad en los errores de los modelos de predicción. Los resultados mostraron que el método con varianza heterocedástica fue el más conservador y realista: por ejemplo, en rodales menores a 5 ha, este método estimó errores de hasta 26,4% (RMSE), mientras que los métodos más simples subestimaron la incertidumbre, reportando errores tan bajos como 5,1%. En rodales grandes (>50 ha), las diferencias entre métodos se redujeron y los errores se estabilizaron entre 5% y 7,2%. Concluyendo que incorporar la estructura de error heterocedástica de los modelos representa mejor la incertidumbre de la estimación poblacional, especialmente en áreas pequeñas o con alta variabilidad.

Pese al avance del método ABA en inventarios forestales, la incertidumbre de sus estimaciones rara vez se cuantifica de forma explícita, lo que limita su uso en

decisiones operativas y en reportes de carbono. Esta brecha es crítica en bosques nativos heterogéneos como los de Roble–Raulí–Coihue (RORACO), donde la alta variabilidad estructural y los errores de modelación y geoposicionamiento pueden sesgar promedios y varianzas a escala de rodal. Para enfrentar este vacío, este estudio integrará el método ABA con propagación de errores y comparará cuatro enfoques: (1) inventario tradicional, (2) ABA tradicional, (3) ABA con incertidumbre del modelo propagada a la población y (4) ABA que incorpora simultáneamente incertidumbre del modelo y error de GPS. Se espera que los resultados establezcan una base metodológica reproducible que descomponga explícitamente las fuentes de variación y entregue estimaciones acompañadas de su error, fortaleciendo la calidad de los inventarios asistidos por LiDAR en ecosistemas nativos complejos y contribuyendo directamente a mejorar la consistencia y credibilidad de los reportes nacionales vinculados a la NDC.

III. CONCLUSIONES

A pesar de que existen estudios que evalúan la propagación de errores en la estimación de variables forestales a nivel de rodal, la mayoría utiliza únicamente datos de terreno y rara vez incorpora información LiDAR; a ello se suma que los casos en ecosistemas nativos son aún más escasos, aun cuando su alta heterogeneidad tiende a incrementar la magnitud de la incertidumbre.

De esta manera, se justifica un estudio que permita establecer una base metodológica que permita estimar la incertidumbre asociada a los inventarios forestales que utilizan información LiDAR, para así poder contribuir en la entrega de información que integre de manera explícita la incertidumbre asociada a las estimaciones de biomasa, ayudando así a la toma de decisiones y acciones para el aporte de la conservación de los bosques nativos del sur de Chile.

IV. BIBLIOGRAFÍA

- Arias-Rodil, M., Diéguez-Aranda, U., & Burkhardt, H. E. (2017). Effects of measurement error in total tree height and upper-stem diameter on stem volume prediction. *Forest Science*, 63(3), 250-260. <https://doi.org/10.5849/FS-2016-087>
- Bahamóndez, C., Pugin, A., Martín, M., Peña, O., Jofré, P., Müller-Using, S., & Rojas, Y. (2010). Estudio Potencial de mitigación del cambio climático asociado a la Ley sobre Recuperación del Bosque Nativo y Fomento Forestal. In *Informe final*: Odepa.
- Bahamóndez, C., Sagardía, R., & Rose, J. (2020). *El bosque nativo en Chile - Resultados del Inventario Forestal Nacional Período 2001-2015*. Instituto Forestal.
- Biber, P., Dursky, J., Pommerening, A., Pretzsch, H., Seifert, E., & Seifert, T. (2000). SILVA 2.2: Benutzerhandbuch (User Manual in German).
- Bouvier, M., Durrieu, S., Fournier, R. A., & Renaud, J.-P. (2015). Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sensing of Environment*, 156, 322-334. <https://doi.org/https://doi.org/10.1016/j.rse.2014.10.004>
- Chave, J., Condit, R., Aguilar, S., Hernández, A., Lao, S., & Perez, R. (2004). Error Propagation and Scaling for Tropical Forest Biomass Estimates. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, 359, 409-420. <https://doi.org/10.1098/rstb.2003.1425>
- Chave, J., Condit, R., Lao, S., Caspersen, J. P., Foster, R. B., & Hubbell, S. P. (2003). Spatial and temporal variation of biomass in a tropical forest: Results from a large census plot in Panama. *Journal of Ecology*, 91(2), 240-252. <https://doi.org/10.1046/j.1365-2745.2003.00757.x>
- CONAF. (2024). *Catastro de los Recursos Vegetacionales de Chile al año 2024* (C. Departamento de Monitoreo, Ed.)
- Echeverría, C. (2024). Nothofagus species in South America. *Curtis's Botanical Magazine*, 41(4), 467-474. <https://doi.org/https://doi.org/10.1111/curt.12601>
- Eid, T., & Næsset, E. (1998). Determination of stand volume in practical forest inventories based on field measurements and photo-interpretation: The Norwegian experience. *Scandinavian Journal of Forest Research*, 13(1-4), 246-254. <https://doi.org/10.1080/02827589809382982>

- Fantner, G. (2013). A brief introduction to error analysis and propagation. In.
- FAO. (2024). *El estado de los bosques del mundo 2024: Innovaciones en el sector forestal para lograr un futuro más sostenible*
- Fassnacht, F. E., Latifi, H., & Hartig, F. (2018). Using synthetic data to evaluate the benefits of large field plots for forest biomass estimation with LiDAR. *Remote Sensing of Environment*, 213, 115-128. <https://doi.org/10.1016/j.rse.2018.05.007>
- Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2024). Remote sensing in forestry: current challenges, considerations and directions. *Forestry*, 97(1), 11-37. <https://doi.org/10.1093/forestry/cpad024>
- Frazer, G. W., Magnussen, S., Wulder, M. A., & Niemann, K. O. (2011). Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. *Remote Sensing of Environment*, 115(2), 636-649. <https://doi.org/10.1016/j.rse.2010.10.008>
- Gatziolis, D., & Andersen, H. E. (2008). A guide to LIDAR data acquisition and processing for the forests of the pacific northwest. *USDA Forest Service - General Technical Report PNW-GTR(768)*, 1-32. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-51249094527&partnerID=40&md5=06dcadd302a7e8a3a4829781ea62b757>
- Gertner, G. Z., & Dzialowy, P. J. (1984). Effects of measurement errors on an individual tree-based growth projection system. *Canadian Journal of Forest Research*, 14(3), 311-316. <https://doi.org/10.1139/x84-057>
- Gobakken, T., & Næsset, E. (2009). Assessing effects of positioning errors and sample plot size on biophysical stand properties derived from airborne laser scanner data. *Canadian Journal of Forest Research*, 39(5), 1036-1052. <https://doi.org/10.1139/X09-025>
- Goodbody, T. R. H., Coops, N. C., Marshall, P. L., Tompalski, P., & Crawford, P. (2017). Unmanned aerial systems for precision forest inventory purposes: A review and case study. *Forestry Chronicle*, 93(1), 71-81. <https://doi.org/10.5558/tfc2017-012>
- Gregoire, T. G. (1998). Design-based and model-based inference in survey sampling: appreciating the difference. *Canadian Journal of Forest Research*, 28(10), 1429-1447. <https://doi.org/10.1139/x98-166>
- Harding, D. J., Lefsky, M. A., Parker, G. G., & Blair, J. B. (2001). Laser altimeter canopy height profiles methods and validation for closed-canopy, broadleaf forests.

- Remote Sensing of Environment*, 76(3), 283-297. [https://doi.org/10.1016/S0034-4257\(00\)00210-8](https://doi.org/10.1016/S0034-4257(00)00210-8)
- Hernández-Stefanoni, J. L., Reyes-Palomeque, G., Castillo-Santiago, M., George-Chacón, S. P., Huechacona-Ruiz, A. H., Tun-Dzul, F., Rondon-Rivera, D., & Dupuy, J. M. (2018). Effects of sample plot size and GPS location errors on aboveground biomass estimates from LiDAR in tropical dry forests. *Remote Sensing*, 10(10), Article 1586. <https://doi.org/10.3390/rs10101586>
- Hosseini, Z., Latifi, H., Naghavi, H., Bakhtiarvand Bakhtiari, S., & Fassnacht, F. E. (2021). Influence of plot and sample sizes on aboveground biomass estimations in plantation forests using very high resolution stereo satellite imagery. *Forestry*, 94(2), 278-291. <https://doi.org/10.1093/forestry/cpaa028>
- Huang, S., Titus, S. J., & Wiens, D. P. (1992). Comparison of nonlinear height-diameter functions for major Alberta tree species. *Canadian Journal of Forest Research*, 22(9), 1297-1304. <https://doi.org/10.1139/x92-172>
- INFOR-INIA. (2014). *Informe Final Proyección Escenario Línea Tendencial 2013 y Escenarios de Mitigación del Sector Silvoagropecuario y Cambio de Uso de Suelo* (Proyecto 81013-Proyecto MAPS CHILE: Mitigation Options for Addressing Climate Change (Alternativas de mitigación para enfrentar el Cambio Climático) Issue.
- Johnson, C. E., & Barton, C. C. (2004). Where in the world are my field plots? Using GPS effectively in environmental field studies. *Frontiers in Ecology and the Environment*, 2(9), 475-482. [https://doi.org/https://doi.org/10.1890/1540-9295\(2004\)002\[0475:WITWAM\]2.0.CO;2](https://doi.org/https://doi.org/10.1890/1540-9295(2004)002[0475:WITWAM]2.0.CO;2)
- Jurjević, L., Liang, X., Gašparović, M., & Balenović, I. (2020). Is field-measured tree height as reliable as believed – Part II, A comparison study of tree height estimates from conventional field measurement and low-cost close-range remote sensing in a deciduous forest. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169, 227-241. <https://doi.org/10.1016/j.isprsjprs.2020.09.014>
- Kankare, V., Vastaranta, M., Holopainen, M., Rätty, M., Yu, X., Hyypä, J., Hyypä, H., Alho, P., & Viitala, R. (2013). Retrieval of forest aboveground biomass and stem volume with airborne scanning LiDAR. *Remote Sensing*, 5(5), 2257-2274. <https://doi.org/10.3390/rs5052257>
- Lefsky, M. A., Cohen, W. B., Parker, G. G., & Harding, D. J. (2002). Lidar remote sensing for ecosystem studies. *BioScience*, 52(1), 19-30. [https://doi.org/10.1641/0006-3568\(2002\)052\[0019:LRSFES\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2002)052[0019:LRSFES]2.0.CO;2)
- López, M., & Sandoval, S. (2023). Estimation of stand density using aerial LiDAR information: Integrating the area-based-approach and individual-tree-detection

- methods in plantations of *Pinus radiata*. *Bosque*, 44(2), 377-386. <https://doi.org/10.4067/S0717-92002023000200377>
- Luoma, V., Saarinen, N., Wulder, M. A., White, J. C., Vastaranta, M., Holopainen, M., & Hyypä, J. (2017). Assessing precision in conventional field measurements of individual tree attributes. *Forests*, 8(2), Article 38. <https://doi.org/10.3390/f8020038>
- McDonald, T., Gann, G. D., Jonson, J., & Dixon, K. W. (2016). *International standards for the practice of ecological restoration – including principles and key concepts*. Society for Ecological Restoration.
- McRoberts, R. E., Næsset, E., Gobakken, T., Chirici, G., Condés, S., Hou, Z., Saarela, S., Chen, Q., Ståhl, G., & Walters, B. F. (2018). Assessing components of the model-based mean square error estimator for remote sensing assisted forest applications. *Canadian Journal of Forest Research*, 48(6), 642-649. <https://doi.org/10.1139/cjfr-2017-0396>
- Molto, Q., Rossi, V., & Blanc, L. (2013). Error propagation in biomass estimation in tropical forests. *Methods in Ecology and Evolution*, 4(2), 175-183. <https://doi.org/10.1111/j.2041-210x.2012.00266.x>
- Moreno, P. C., Gezan, S. A., Palmas, S., Escobedo, F. J., & Cropper, W. P. (2018). Exploring stand and tree variability in mixed *Nothofagus* second-growth forests through multivariate analyses. *Bosque*, 39(3), 397-410. <https://doi.org/10.4067/S0717-92002018000300397>
- Müller-Using, S. (2020). *El manejo de renovales de Roble-Raulí-Coihue en una resumida mirada: Estadísticas e investigaciones en curso*. Instituto Forestal.
- Müller-Using, S., Bahamóndez, C., Sagardía, R., Vergara, G., & Reyes, R. (2021). *Bosques Nativos de Chile: estado, presiones e importancia en una época de cambios*. INFOR. <https://doi.org/10.52904/20.500.12220/30461>
- Næsset, E. (2002). Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, 80(1), 88-99. [https://doi.org/10.1016/S0034-4257\(01\)00290-5](https://doi.org/10.1016/S0034-4257(01)00290-5)
- Næsset, E., & Gobakken, T. (2008). Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sensing of Environment*, 112(6), 3079-3090. <https://doi.org/10.1016/j.rse.2008.03.004>
- Ortiz-Reyes, A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., De Los Santos-Posadas, H. M., Schneider, L., Aguirre-Salado, C., & Peduzzi, A. (2019). Transectos de datos LiDAR: una estrategia de muestreo para estimar biomasa aérea en áreas forestales. *Madera Bosques*, 25, e2531872.

- Penner, M., Pitt, D., & Woods, M. (2013). Parametric vs. nonparametric LiDAR models for operational forest inventory in boreal Ontario. *Canadian Journal of Remote Sensing*, 39, 426-443. <https://doi.org/10.5589/m13-049>
- Pretzsch, H., Biber, P., & Ďurský, J. (2002). The single tree-based stand simulator SILVA: Construction, application and evaluation. *Forest Ecology and Management*, 162(1), 3-21. [https://doi.org/10.1016/S0378-1127\(02\)00047-6](https://doi.org/10.1016/S0378-1127(02)00047-6)
- Puliti, S., Dash, J. P., Watt, M. S., Breidenbach, J., & Pearse, G. D. (2020). A comparison of UAV laser scanning, photogrammetry and airborne laser scanning for precision inventory of small-forest properties. *Forestry*, 93(1), 150-162. <https://doi.org/10.1093/forestry/cpz057>
- Saarela, S., Schnell, S., Grafström, A., Tuominen, S., Nordkvist, K., Hyyppä, J., Kangas, A., & Ståhl, G. (2015). Effects of sample size and model form on the accuracy of model-based estimators of growing stock volume. *Canadian Journal of Forest Research*, 45(11), 1524-1534. <https://doi.org/10.1139/cjfr-2015-0077>
- Salas, C., Ene, L., Ojeda, N., & Soto, H. (2010). Métodos estadísticos paramétricos y no paramétricos para predecir variables de rodal basados en Landsat ETM+: una comparación en un bosque de Araucaria araucana en Chile. *Bosque (Valdivia)*, 31, 179-194. http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0717-92002010000300002&nrm=iso
- Sandoval, S., & Bustamante-Ortega, R. (2020). Estimation of uncertainty in airborne lidar inventories using approaches based on bootstrapping-pairs methods. *Forests*, 11(12), 1-12, Article 1305. <https://doi.org/10.3390/f11121305>
- Stereńczak, K., Lisańczuk, M., Parkitna, K., Mitelsztedt, K., Mroczek, P., & Miścicki, S. (2018). The influence of number and size of sample plots on modelling growing stock volume based on airborne laser scanning. *Drewno*, 61. <https://doi.org/10.12841/wood.1644-3985.D11.04>
- Strunk, J., Temesgen, H., Andersen, H. E., Flewelling, J. P., & Madsen, L. (2012). Effects of lidar pulse density and sample size on a model-assisted approach to estimate forest inventory variables. *Canadian Journal of Remote Sensing*, 38(5), 644-654. <https://doi.org/10.5589/m12-052>
- Thompson, S. K. (2012). *Sampling, Third Edition*. <https://doi.org/10.1002/9781118162934>
- Tompalski, P., White, J. C., Coops, N. C., Wulder, M. A., Leboeuf, A., Sinclair, I., Butson, C. R., & Lemonde, M. O. (2021). Quantifying the precision of forest stand height and canopy cover estimates derived from air photo interpretation. *Forestry*, 94(5), 611-629. <https://doi.org/10.1093/forestry/cpab022>

- Vauhkonen, J., Maltamo, M., McRoberts, R., & Næsset, E. (2014). Introduction to Forestry Applications of Airborne Laser Scanning. In (Vol. 27, pp. 1-16). https://doi.org/10.1007/978-94-017-8663-8_1
- Wang, Y., Lehtomäki, M., Liang, X., Pyörälä, J., Kukko, A., Jaakkola, A., Liu, J., Feng, Z., Chen, R., & Hyyppä, J. (2019). Is field-measured tree height as reliable as believed – A comparison study of tree height estimates from field measurement, airborne laser scanning and terrestrial laser scanning in a boreal forest. *ISPRS Journal of Photogrammetry and Remote Sensing*, 147, 132-145. <https://doi.org/10.1016/j.isprsjprs.2018.11.008>
- Wertz, B., Ochał, W., Bronisz, K., & Orzeł, S. (2025). Effect of the interaction between user experience and hypsometer type on the uncertainty of ground-based tree height measurement. *Forestry: An International Journal of Forest Research*. <https://doi.org/10.1093/forestry/cpaf022>
- White, J., Tompalski, P., Vastaranta, M., Wulder, M., Saarinen, N., Stepper, C., & Coops, N. (2017). *A model development and application guide for generating an enhanced forest inventory using airborne laser scanning data and an area-based approach*. <https://doi.org/10.13140/RG.2.2.26770.96964>
- Zeng, W., Tomppo, E., Healey, S. P., & Gadov, K. V. (2015). The national forest inventory in China: History - Results - International context. *Forest Ecosystems*, 2(1), Article 23. <https://doi.org/10.1186/s40663-015-0047-2>
- Zhang, J., Hu, J., Lian, J., Fan, Z., Ouyang, X., & Ye, W. (2016). Seeing the forest from drones: Testing the potential of lightweight drones as a tool for long-term forest monitoring. *Biological Conservation*, 198, 60-69. <https://doi.org/10.1016/j.biocon.2016.03.027>