



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

USO DE INFORMACIÓN LIDAR Y REDES NEURONALES ARTIFICIALES
PARA LA ESTIMACION DE BIOMASA EN SITIOS DE RECUPERACIÓN DE
BOSQUES DE *NOTHOFAGUS*

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

POR: Lorena Ormeño Rivas

Profesor Guía: Simón Sandoval Rocha

Octubre, 2025

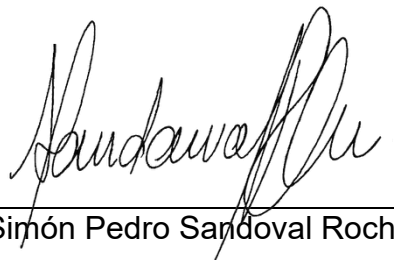
Concepción, Chile

© 2024, Lorena Paz Ormeño Rivas

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

USO DE INFORMACIÓN LIDAR Y REDES NEURONALES
ARTIFICIALES PARA LA ESTIMACIÓN DE BIOMASA EN SITIOS DE
RECUPERACIÓN DE BOSQUES DE *NOTHOFAGUS*

Profesor Guía

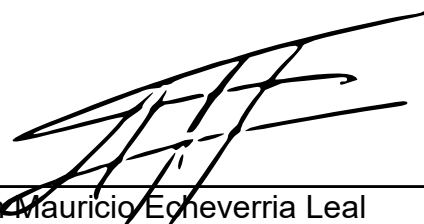


Simón Pedro Sandoval Rocha

Profesor Asistente

Ingeniero Forestal, Dr.

Profesor Co-Guía



Cristian Mauricio Echeverría Leal

Profesor Titular

Ingeniero Forestal, PhD

DEDICATORIA

A mi familia, Ana Rivas, Freddy Ormeño M., Leticia Ormeño, Vanesa Ormeño, Freddy Ormeño R., y a mi pareja Ignacio Villagrán.

AGRADECIMIENTOS

Deseo agradecer a mis profesores Simón Sandoval y Cristian Echeverría por su guía, apoyo y conocimiento brindado (tanto en esta investigación, como en los años de carrera), que me incentiva a continuar aprendiendo.

También agradezco a mi familia, a mi amiga Estefany Villalobos y mi pareja, por su apoyo incondicional durante estos años.

TABLA DE CONTENIDO

RESUMEN.....	viii
I. INTRODUCCIÓN.....	1
II. MARCO TEÓRICO.....	4
2.1 Restauración forestal y su impacto en el secuestro de carbono.....	4
2.2 Tecnología LiDAR en la estimación de atributos forestales.....	8
2.3 Redes Neuronales Artificiales en la Modelación de Biomasa.....	11
III. CONCLUSIÓN.....	17
V. BIBLIOGRAFÍA.....	18

ÍNDICE DE ILUSTRACIONES

Figura 1. Relación conceptual entre la integración de datos LiDAR y RNA para la cuantificación de biomasa en ecosistemas en recuperación de <i>Nothofagus</i> en Chile.....	15
--	----

RESUMEN

La biomasa aérea es un indicador clave en la restauración forestal, ya que permite evaluar procesos como el secuestro de carbono, un aspecto fundamental en la recuperación y manejo de ecosistemas. Este estudio aborda la estimación de la biomasa aérea en un área de reforestación mediante plantación agrupada y en filas de plantación regulares con la especie *Nothofagus obliqua*, integrando información obtenida con tecnología LiDAR (*Light Detection and Ranging*) y modelación mediante redes neuronales artificiales (RNA). La investigación se llevará a cabo en el predio "El Huachito", ubicado en la comuna de Santa Bárbara, en la región del Biobío. El trabajo se enfocó en el procesamiento de datos LiDAR mediante algoritmos de segmentación adaptados a la configuración de plantación en casillas de tres, y en explorar diferentes arquitecturas de redes neuronales artificiales, evaluando los distintos hiperparámetros de la red, para estimar de manera precisa la biomasa de los componentes. Se destaca el potencial de las herramientas tecnológicas avanzadas en la mejora del monitoreo y manejo de ecosistemas reforestados.

I. INTRODUCCIÓN

La restauración de ecosistemas forestales se reconoce como un enfoque clave para revertir la degradación y que puede aportar a la recuperación de múltiples servicios ecosistémicos, tales como la provisión de agua limpia, la estabilización de los suelos, la conservación de la biodiversidad y el secuestro de carbono (UNEP, 2021). Este último servicio resulta especialmente relevante en contexto de cambio climático, y la restauración se mantiene como una de las estrategias más efectivas para su mitigación (Bastin et al., 2019; Locatelli et al., 2011). En particular, esto se logra mediante el aumento sostenido de la tasa de secuestro de carbono desde la atmósfera, a través de la acumulación de biomasa vegetal en los ecosistemas recuperados (Gann., et al 2019).

El monitoreo de estas iniciativas de restauración requiere indicadores específicos, entre los cuales la biomasa aérea de los árboles representa una variable clave. Esta tiene estrecha relación con el almacenamiento de carbono, la dinámica estructural del bosque y, por lo tanto, con el potencial de mitigación del cambio climático (Almeida et al., 2019a; Locatelli et al., 2015; Zhao et al., 2015). Sin embargo, la medición directa de la biomasa forestal enfrenta importantes desafíos. Esto debido a la dificultad y los costos asociados a la recolección de datos en terreno (Weiskittel et al., 2015). Ante estas limitaciones, se ha impulsado el desarrollo de métodos que aprovechan herramientas de

teledetección, como *Light Detection and Ranging* (LiDAR). Esta tecnología permite generar estimaciones precisas y obtener información detallada sobre la estructura tridimensional del bosque (Silva et al., 2016; Lefsky et al., 2002). Existen dos métodos principales para la estimación de variables forestales a partir de datos LiDAR: el enfoque basado en el área (ABA: *area-based approach*) y el enfoque basado en la detección de árboles (ITD: *individual tree detection*). El método ITD mejora la caracterización estructural del bosque, dado que permite extraer métricas como la densidad de individuos y la altura del árbol individual mediante la identificación y segmentación de cada uno de los árboles (Roussel et al., 2020; Silva et al., 2016). No obstante, estas estimaciones requieren de modelos robustos capaces de relacionar métricas derivadas de la nube de puntos con variables de interés, como la biomasa. En este sentido, las redes neuronales artificiales (RNA) han emergido como una alternativa prometedora frente a los modelos tradicionales, debido a su capacidad para capturar relaciones no lineales y patrones complejos en grandes volúmenes de datos (Fausett, 1994; Diamantopoulou et al., 2009). Un aspecto crucial en su aplicación es la definición de su arquitectura, es decir, la cantidad de capas ocultas, neuronas por capa y funciones de activación utilizadas. Estos elementos de las RNA determinan la capacidad para aprender de relaciones biológicas complejas, lo que resulta fundamental en la estimación de variables de árbol como lo es la biomasa (Fausett, 1994; Özçelik et al., 2017).

A pesar de su potencial, la aplicación de RNA y LiDAR para la estimación de biomasa a nivel de árbol individual en bosques templados de Chile ha sido limitada (Pérez, 2022), siendo aún más escasas las experiencias relacionadas con actividades de reforestación mediante técnicas de plantación por grupos (Almeida et al., 2019a; Almeida et al., 2019b).

El presente estudio tiene como objetivo identificar y evaluar una arquitectura de RNA que permita estimar con precisión la biomasa de árboles de la especie *Nothofagus obliqua* plantados con fines de reforestación, utilizando información LiDAR aérea a nivel de árbol individual. Este enfoque es fundamental para obtener estimaciones de la biomasa de los árboles, proponiendo así una metodología como herramienta para el monitoreo de bosques en restauración y su impacto en la mitigación del cambio climático.

II. MARCO TEÓRICO

2.1 Restauración forestal y su impacto en el secuestro de carbono

En la actualidad existen compromisos mundiales tendientes a enfrentar de manera adecuada la mitigación y adaptación al cambio climático, como la Convención Marco de Naciones Unidas sobre el Cambio Climático y la Conferencia de las Partes en el Acuerdo de París (COP 21, 2015). El objetivo de estas iniciativas es reforzar la respuesta mundial a la amenaza del cambio climático. Chile está adherido a estas iniciativas desde 1994 y ha implementado algunas medidas en ese sentido como la ley 21.455, Ley Marco de Cambio Climático (LMCC, 2022), que establece un marco jurídico para hacer frente a los desafíos que presenta el cambio climático, con la finalidad de alcanzar y mantener la neutralidad de emisiones de gases de efecto invernadero al año 2050, asegurando el cumplimiento de los compromisos establecidos en el Acuerdo de París.

La LMCC reconoce las Contribuciones Determinadas a nivel Nacional (NDC) como un instrumento clave de gestión del cambio climático, alineado con los requerimientos de la comunidad científica. Estas contribuciones contemplan compromisos en cinco áreas: i) pilar social de transición justa y desarrollo

sostenible, ii) mitigación, iii) adaptación, iv) integración, y v) medios de implementación. Como una medida de mitigación y adaptación integrados se incluye la recuperación de 200.000 hectáreas de bosques nativos, para capturar alrededor de 0,9 a 1,2 MtCO₂eq anuales al año 2030, lo que aporta tanto a la conservación de sumideros de carbono como a la resiliencia ecológica del territorio (NDC, 2025).

La restauración de ecosistemas es definida por *United Nations Environment Program* (UNEP, 2021) como “el proceso de detener y revertir la degradación, lo que da como resultado una mejora en los servicios ecosistémicos y la recuperación de la biodiversidad, la cual puede adoptar diversas trayectorias dependiendo de los objetivos y condiciones locales”. La restauración de ecosistemas boscosos genera un beneficio clave, la mitigación de los efectos del cambio climático, dado que puede incrementar significativamente los niveles de carbono en el suelo y en la vegetación rehabilitada (IUCN & WRI, 2014; Bastin et al., 2019)

En este sentido, hoy en día existen varias iniciativas que promueven la restauración forestal (Chazdon et al., 2017). En este contexto, una de las estrategias de mayor uso para acelerar los procesos de restauración es la reforestación (Sandoval-García et al., 2022). Este método contribuye a reestablecer la conexión de los hábitats, aumentar su extensión y mejorar su calidad aportando a la conservación de la biodiversidad. Una dimensión clave

de las estrategias de reforestación es la selección de ecosistemas y especies que aseguren la recuperación ecológica, y contribuyan a la provisión de servicios ecosistémicos (Gann., et al 2019; UNEP, 2021).

En este contexto, los bosques del género *Nothofagus* cumple un rol ecológico central en los ecosistemas forestales del sur de Chile y Argentina, donde se distribuye a lo largo de diversos gradientes ambientales. (Veblen et al., 1996). Estas especies conforman el estrato superior del bosque, contribuyendo de manera decisiva a la estructura del dosel y proporcionando hábitats fundamentales para una gran variedad de flora y fauna (Echeverría, 2024). Su presencia también está asociada a procesos ecológicos esenciales como la formación de suelos y el ciclo de nutrientes. Desde una perspectiva funcional, los bosques dominados por *Nothofagus* poseen una alta capacidad de almacenamiento de carbono (Echeverría, 2024; Vergara-Díaz & Herrera-Machuca, 2021). Sin embargo, estos ecosistemas han sido significativamente afectados por la presión antrópica, experimentando una reducción de su superficie como resultado de la expansión agrícola, forestal y ganadera (Echeverría et al., 2006; Heilmayr et al., 2016). Esta combinación de funciones ecológicas estratégicas y vulnerabilidad ante disturbios convierte a los bosques de *Nothofagus* en un objetivo para las iniciativas de restauración ecológica y mitigación del cambio climático.

Dado lo anterior, surge la necesidad de contar con mecanismos que permitan evaluar objetivamente los avances de las iniciativas de restauración de ecosistemas. Para medir el progreso hacia las metas y objetivos de restauración, se busca evaluar el grado de recuperación de los atributos ecosistémicos mediante indicadores específicos y cuantificables (Nelson et al., 2019). Existen indicadores tales como la tasa de reclutamiento de especies nativas leñosas por superficie (normalmente expresada en una hectárea), la riqueza de especies o biomasa de especies nativas.

La biomasa aérea de los bosques es un indicador clave que se relaciona con la disminución del CO₂ atmosférico (Ganamé et al., 2020). Este es un indicador que permite evaluar el éxito en proyectos de restauración, debido a que representa uno de los resultados más relevantes que se persiguen en las actividades de recuperación de los ecosistemas forestales, que es, la mitigación potencial del cambio climático (Almeida et al., 2019a; Locatelli et al., 2015). Como se mencionó anteriormente este proceso depende de aumentar sustancialmente la tasa de secuestro de carbono desde la atmosfera mediante la acumulación de biomasa vegetal (Gann., et al 2019; Locatelli et al., 2015).

Por esta razón, la estimación precisa de la biomasa forestal y del carbono se han convertido en un aspecto central, tanto para la gestión de los bosques como para las decisiones políticas (Weiskittel et al., 2015). Además de estudios relacionados a la recuperación de bosques (Almeida et al., 2019a; Locatelli et al., 2015), el

ciclo de los nutrientes y los flujos de energía asociados al crecimiento de los árboles, como la fotosíntesis (Zhao et al., 2015).

No obstante, existen limitaciones en el proceso de recolección de datos para la medición de la biomasa de los árboles, pues esto implica talar y pesar los diferentes componentes de la biomasa, lo que implica trabajar tanto en terreno como laboratorio (Parresol, 1999; Weiskittel et al., 2015). Es frecuente que los investigadores forestales requieran ecuaciones de biomasa para árboles individuales con el fin de estimar con exactitud los distintos componentes de la biomasa (Kalkanlı Genç et al., 2023; Zhao et al., 2015). Parresol (1999) afirma que todos los métodos de estimación de biomasa del rodal deben incorporar, al menos en su desarrollo, una predicción de la biomasa de los árboles individuales, y es fundamental que la suma de las estimaciones de los componentes sea coherente con la biomasa total del árbol. Contar con la precisión de estos datos permite a los investigadores llevar a cabo análisis acerca de la eficacia de las actividades silvícolas pasadas (Lee et al., 2010), evaluar el éxito de la restauración e impulsar la toma segura de decisiones acerca de próximas actividades restaurativas a realizar (Almeida et al., 2019b).

2.2 Tecnología LiDAR en la estimación de atributos forestales

En este contexto, las tecnologías de sensoramiento remoto se han consolidado como herramientas para estimar biomasa de forma no destructiva (Lefsky et al., 2002), siendo una de las más destacadas las tecnologías basadas en Light Detection and Ranging (LiDAR). Esta tecnología emite haces de luz hacia los objetos en la superficie y mide el tiempo en que tardan los reflejos en ser detectados por el sensor (Carter et al, 2012; Roussel et al., 2020). Estos sensores generan una nube de puntos producto del contacto del haz con cada elemento de la vegetación, generando una representación tridimensional del bosque (Lefsky et al., 2002). Los sensores pueden montarse en vehículos aéreos tripulados o no tripulados, estos se conocen como ALS (*Airborne Laser Scanning*), así como también existen escáner de uso terrestre o TLS (*Terrestrial Laser Scanning*) (Tordesillas, 2014).

LiDAR tiene el potencial de penetrar en el dosel forestal, lo que permite caracterizar de forma precisa los parámetros estructurales del dosel (Almeida et al., 2019b; Lefsky et al., 2002). Esto debido a que las variables obtenidas desde la nube de puntos, conocidas como métricas, se pueden relacionar con atributos del estado del rodal recopiladas del muestreo en campo. Esta correspondencia permite escalar la información desde parcelas hacia niveles mayores de análisis, esto puede mejorar la estimación poblacional en comparación con las estimaciones que se realizan con los inventarios tradicionales, reduciendo el tiempo y los costos asociados a su ejecución (Sandoval & Ortega, 2020; Mielcarek et al., 2018).

Para la estimación de variables forestales a partir de datos LiDAR, existen dos métodos principales (Hyypä et al., 2008; Tordesillas, 2014): el enfoque basado en el área (ABA: *area-based approach*) y el enfoque basado en la detección de árboles (ITD: *individual tree detection*). El método ITD utiliza un algoritmo que permite la identificación, individualización y segmentación de los árboles dentro del dosel, brindando información muy útil al facilitar la medición de parámetros como la densidad de individuos, el tamaño de copa o la altura del árbol (Roussel et al., 2020; Silva., et al 2016).

El método ITD es particularmente relevante, dado que la caracterización precisa del bosque a nivel de árbol individual amplía su aplicabilidad a disciplinas en las que se valora un mayor detalle, tales como la ecología, el estudio del hábitat de la vida silvestre (Hinsley et al., 2002; Silva et al., 2016; Vierling et al., 2008) y seguimiento de la recuperación estructural de los bosques después de perturbaciones (Lee et al., 2025). Además, permite mejorar la estimación de la altura de los árboles, el área y volumen de la copa, la estructura del dosel y la biomasa (Gougeon & Leckie, 2003; Lee et al., 2010). Tanto el método ITD como el ABA, dependiendo de la variable a evaluar, requieren de ecuaciones para la estimación en sus respectivos niveles, para estimar atributos como la biomasa o volumen (López & Sandoval, 2023).

Así, el método ITD es particularmente complejo debido a que la estimación depende, en una fase previa, de la capacidad de localizar y segmentar cada uno

de los árboles de interés (Saeed et al., 2024; Silva et al., 2016). Para segmentar, los algoritmos generalmente identifican los ápices de las copas con el modelo de altura del dosel y luego aplican procedimientos de segmentación para delimitar cada árbol (Silva et al., 2016; Li et al., 2012). La efectividad del método depende de la resolución de los datos, las características del bosque y los parámetros de los algoritmos utilizados (Dalponte & Coomes, 2016). Esto destaca la necesidad de contar con precisión en esta etapa del flujo de trabajo, ya que los errores en la detección o segmentación se propagan a los modelos de estimación de biomasa (Saeed et al., 2024; Vauhkonen et al., 2022).

2.3 Redes Neuronales Artificiales en la Modelación de Biomasa

Las métricas LiDAR pueden relacionarse con variables del estado del rodal recopiladas del muestreo en campo para construir modelos que permiten estimar diversas variables del bosque (López & Sandoval, 2023). Entre las estrategias de modelación más utilizadas para este propósito se encuentran los modelos paramétricos (lineales y no lineales), modelos no paramétricos y de aprendizaje automático entre los cuales se encuentran Random Forest, Support Vector Machine y las Redes Neuronales Artificiales (RNA) (Corte et al., 2020).

Las métricas derivadas de la nube de puntos LiDAR pueden ser utilizadas como predictores en los modelos RNA para la biomasa de los árboles (Schuh et al., 2020). Las RNA pueden definirse como técnicas de modelación de inteligencia artificial (Tiryaki & Aydın, 2014) y son un sistema de procesamiento de la información que intenta replicar el comportamiento de un cerebro humano (Fausett, 1994; Özçelik et al., 2010). Las RNA tienen una estructura altamente interconectada, y constan de un gran número de elementos de procesamiento llamados neuronas, que se disponen en diferentes capas de la red (Tiryaki & Aydın, 2014). Así, el funcionamiento de una RNA se basa en los siguientes principios: (i) el procesamiento de la información ocurre a través de múltiples unidades simples (neuronas o nodos), (ii) estas unidades están interconectadas mediante enlaces de comunicación, (iii) cada enlace posee un peso asociado y (iv) cada unidad aplica una función de activación, generalmente no lineal a su entrada de red, para determinar su salida (Fausett, 1994).

El tipo de red neuronal más utilizado para hacer predicciones es el perceptrón multicapa, el cual se compone de una capa de entrada, una o varias capas ocultas y una capa de salida, que permiten a la red aprender las relaciones entre las variables de entrada y de salida (Tiryaki & Aydın, 2014; Vahedi, 2016). En este tipo de redes, el algoritmo más común para el entrenamiento es el de retropropagación del error (backpropagation), el cual consta de tres etapas principales. Primero, los datos de entrada se propagan hacia adelante a través de la red para generar una salida; luego, se calcula el error comparando esta

salida con el valor objetivo y dicho error se propaga hacia atrás a través de la red; finalmente, los pesos de las conexiones se ajustan en función de ese error, con el objetivo de minimizar el error de predicción iterativamente en cada ciclo de entrenamiento (Fausett, 1994).

La selección de la arquitectura óptima no sigue un criterio fijo, por lo que habitualmente se emplea un procedimiento de prueba y error para ajustar el número de capas ocultas y neuronas en función del desempeño del modelo (Özçelik et al., 2010; Vahedi, 2016). Por lo tanto, en la modelación con RNA es fundamental definir la arquitectura y estructura, las propiedades de sus nodos, y los métodos de entrenamiento y aprendizaje. Estas directrices establecen los pesos iniciales y determinan como ajustarlos para optimizar el desempeño del modelo (Diamantopoulou et al., 2009; Fausett, 1994). Las RNA se han convertido en herramientas de estimación muy populares por su capacidad para aprender de los datos y su potencial para describir con precisión el comportamiento de sistemas no lineales complejos (Diamantopoulou et al., 2009). Además, no están sujetas a restricciones estadísticas, como la ausencia de colinealidad entre las variables y relaciones lineales entre los datos (Jensen et al., 1999), permitiendo incorporar mayor cantidad de variables predictoras (o métricas LiDAR).

El empleo de RNA ha sido evaluado para la modelación de diversas variables clave en el ámbito forestal, tanto en la investigación como en la conservación de ecosistemas. Diamantopoulou et al. (2009), utilizan una RNA para estimar el

volumen de los árboles dominantes en bosques reforestados en Grecia, con el fin de optimizar el diseño de la reforestación en función de las condiciones del sitio. Otro ejemplo del uso de las RNA se presentó en el estudio de Vahedi (2016), quien compara el desempeño de ecuaciones alométricas y RNA para predecir la biomasa aérea de bosques mixtos de hayas. En otras investigaciones las RNA se han empleado para estimar la biomasa aérea en especies del género *Pinus* (Özçelik et al., 2017) y para estimar la biomasa de la especie de *Cedrus libani* en bosques naturales de Turquía (Kalkanlı Genç et al., 2023). Así, modelos de estimación basados en RNA integrados con información LiDAR han permitido optimizar la estimación de la biomasa de árboles y bosques. Zulkiflee et al. (2023) integran imágenes multiespectrales con datos LiDAR y aplican algoritmos de aprendizaje automático, incluyendo RNA para estimar la biomasa y generar mapas de carbono en un bosque tropical. Los resultados obtenidos fueron satisfactorios, lo que evidencia el potencial de estas herramientas combinadas para mejorar la precisión de las estimaciones. Sin embargo, en los estudios, no se incorpora explícitamente la propiedad de aditividad de la biomasa en el diseño de la arquitectura del modelo.

Asimismo, la aplicación de RNA para la estimación de biomasa a nivel de árbol individual en bosques templados de Chile ha sido limitada (Pérez, 2022), siendo inexistente en contextos de recuperación de bosques. Esta ausencia representa un vacío relevante, dado que estos escenarios presentan desafíos estructurales particulares. Además, las metodologías existentes tienden a segmentar

individuos de manera aislada (Lee et al., 2010; Li et al., 2012), sin considerar la unidad funcional que podrían representar grupos de árboles plantados conjuntamente, lo que requiere enfoques de modelación adaptados a condiciones menos estudiadas.

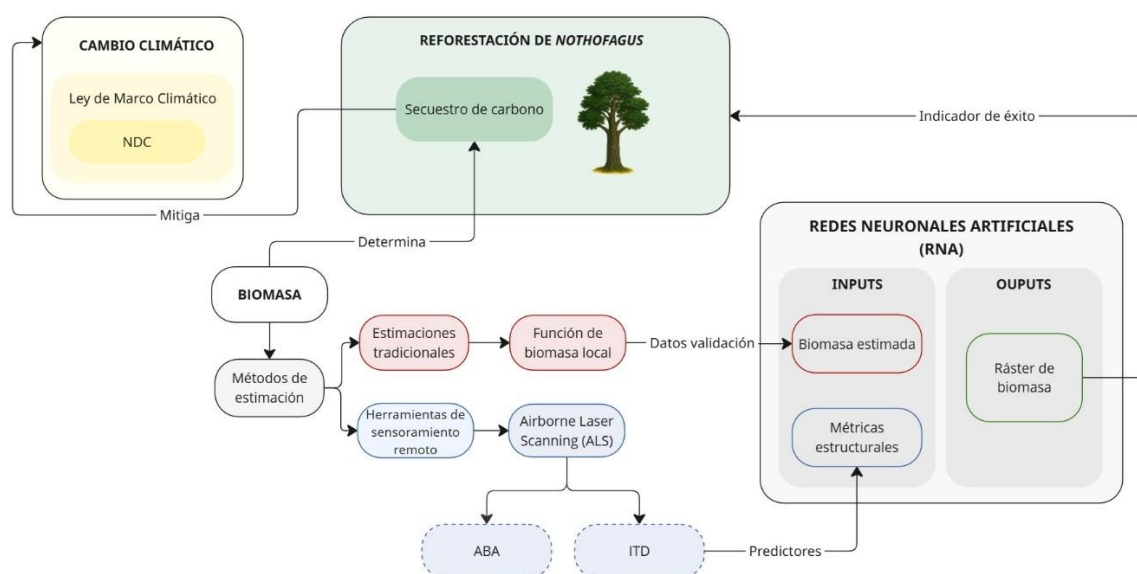


Figura 1. Relación conceptual entre la integración de datos LiDAR y RNA para la cuantificación de biomasa en ecosistemas en recuperación de *Nothofagus* en Chile. Ilustra el marco conceptual de la investigación conectando los compromisos nacionales de mitigación de cambio climático con el flujo de trabajo y uso integrado de herramientas tecnológicas como LiDAR y RNA para estimar la biomasa de bosques en recuperación, dada su relevancia como indicador de éxito y cuantificación de la captura de carbono, esencial para la mitigación de cambio climático.

El presente estudio tiene como objetivo identificar y evaluar una arquitectura de red neuronal artificial que permita estimar con precisión la biomasa de árboles plantados de la especie *Nothofagus obliqua* utilizando información LiDAR a nivel

de árbol individual. Este enfoque es fundamental para obtener estimaciones precisas de la biomasa de los árboles, proponiendo así un flujo de trabajo para el monitoreo continuo de bosques en restauración, que permita además la evaluación del éxito de la plantación y la gestión de estrategias de conservación.

III. CONCLUSIÓN

El uso combinado de tecnología LiDAR y redes neuronales artificiales destaca como un enfoque eficiente y robusto para la estimación de biomasa en bosques. En particular, la capacidad de LiDAR para capturar con precisión la información estructural del dosel mediante enfoques basados en ITD resulta fundamental para obtener datos fiables sobre la vegetación. Esta precisión, junto con la flexibilidad de las RNA para modelar datos complejos, permite generar estimaciones consistentes en ecosistemas forestales con alta variabilidad.

No obstante, lograr estimaciones precisas de biomasa en escenarios de recuperación de bosques de *Nothofagus* con configuraciones regulares de plantación, requiere metodologías que se adapten a estas condiciones. En este contexto, el presente estudio propone una metodología como herramienta para el monitoreo continuo de bosques en restauración, que permita además la evaluación del éxito de la plantación y la gestión de estrategias de conservación.

V. BIBLIOGRAFÍA

1. Acuerdo de París, adoptado en la 21.^a sesión de la Conferencia de las Partes (cop) del 30 de noviembre al 12 de diciembre de 2015 en París, Francia.
2. Almeida, D. R. A., Broadbent, E. N., Zambrano, A. M. A., Wilkinson, B. E., Ferreira, M. E., Chazdon, R., Meli, P., Gorgens, E. B., Silva, C. A., Stark, S. C., Valbuena, R., Papa, D. A., & Brancalion, P. H. S. (2019a). Monitoring the structure of forest restoration plantations with a drone-lidar system. *International Journal of Applied Earth Observation and Geoinformation*, 79, 192-198. <https://doi.org/https://doi.org/10.1016/j.jag.2019.03.014>
3. Almeida, D. R. A., Stark, S. C., Chazdon, R., Nelson, B. W., Cesar, R. G., Meli, P., Gorgens, E. B., Duarte, M. M., Valbuena, R., Moreno, V. S., Mendes, A. F., Amazonas, N., Gonçalves, N. B., Silva, C. A., Schiatti, J., & Brancalion, P. H. S. (2019b). The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *Forest Ecology and Management*, 438, 34-43. <https://doi.org/https://doi.org/10.1016/j.foreco.2019.02.002>
4. Bastin, J.-F., Finegold, Y., Garcia, C., Mollicone, D., Rezende, M., Routh, D., Zohner, C. M., & Crowther, T. W. (2019). The global tree restoration potential. *Science*, 365(6448), 76–79. <https://doi.org/10.1126/science.aax0848>
5. Carter J, K Schmid, K Waters, L Betzhold, B Hadley, R Mataosky, J Halleran. (2012). Lidar 101: An introduction to Lidar technology, data, and applications. Charleston, SC. National oceanic and atmospheric administration (NOAA), Coastal Services Center. 76 p. <https://coast.noaa.gov/data/digitalcoast/pdf/lidar-101.pdf>
6. Chazdon, R. L., Brancalion, P. H. S., Lamb, D., Laestadius, L., Calmon, M., & Kumar, C. (2017). A Policy-Driven Knowledge Agenda for Global Forest and Landscape Restoration. *Conservation Letters*, 10(1), 125-132. <https://doi.org/https://doi.org/10.1111/conl.12220>
7. Dalponte, M., & Coomes, D. A. (2016). Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data.

Methods in Ecology and Evolution, 7(10), 1236-1245.
<https://doi.org/https://doi.org/10.1111/2041-210X.12575>

8. Diamantopoulou, M. J., Milios, E., Doganos, D., & Bistinas, I. (2009). Artificial neural network modeling for reforestation design through the dominant trees bole-volume estimation Article. *Natural Resource Modeling*, 22(4), 511-543. <https://doi.org/10.1111/j.1939-7445.2009.00051.x>
9. 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>
10. Echeverria, C., Coomes, D., Salas, J., Rey-Benayas, J. M., Lara, A., & Newton, A. (2006). Rapid deforestation and fragmentation of Chilean Temperate Forests. *Biological Conservation*, 130(4), 481–494. <https://doi.org/https://doi.org/10.1016/j.biocon.2006.01.017>
11. Fausett, L. (1994). Fundamentals of neural networks: Architectures, algorithms, and applications.
12. Ganamé, M., Bayen, P., Dimobe, K., Ouédraogo, I., & Thiombiano, A. (2020). Aboveground biomass allocation, additive biomass and carbon sequestration models for *Pterocarpus erinaceus* Poir. in Burkina Faso. *Heliyon*, 6(4). <https://doi.org/10.1016/j.heliyon.2020.e03805>
13. Gann, G. D., McDonald, T., Walder, B., Aronson, J., Nelson, C. R., Jonson, J., Hallett, J. G., Eisenberg, C., Guariguata, M. R., Liu, J., Hua, F., Echeverría, C., Gonzales, E., Shaw, N., Decler, K., & Dixon, K. W. (2019). International principles and standards for the practice of ecological restoration. Second edition. *Restoration Ecology*, 27(S1), S1-S46. <https://doi.org/https://doi.org/10.1111/rec.13035>
14. Gougeon, F. A., & Leckie, D. G. (2003). Forest information extraction from high spatial resolution images using an individual tree crown approach.
15. Heilmayr, R., Echeverría, C., Fuentes, R., & Lambin, E. F. (2016). A plantation-dominated forest transition in Chile. *Applied Geography*, 75, 71–82. <https://doi.org/https://doi.org/10.1016/j.apgeog.2016.07.014>

16. Hinsley, S. A., Hill, R. A., Gaveau, D. L. A., & Bellamy, P. E. (2002). Quantifying woodland structure and habitat quality for birds using airborne laser scanning. *Functional Ecology*, 16(6), 851-857. <https://doi.org/https://doi.org/10.1046/j.1365-2435.2002.00697.x>
17. Hyypä, J., Hyypä, H., Leckie, D., Gougeon, F., Yu, X., & Maltamo, M. (2008). Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *International Journal of Remote Sensing*, 29(5), 1339-1366. <https://doi.org/10.1080/01431160701736489>
18. IUCN and WRI (2014). A guide to the Restoration Opportunities Assessment Methodology (ROAM): Assessing forest landscape restoration opportunities at the national or sub-national level. Working Paper (Road-test edition). Gland, Switzerland: IUCN. 125pp
19. Jensen, J. R., Qiu, F., & Ji, M. (1999). Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data Article. *International Journal of Remote Sensing*, 20(14), 2805-2822. <https://doi.org/10.1080/014311699211804>
20. Kalkanlı Genç, Ş., Diamantopoulou, M. J., & Özçelik, R. (2023). Tree Biomass Modeling Based on the Exploration of Regression and Artificial Neural Networks Approaches Article. *Forests*, 14(12), Article 2429. <https://doi.org/10.3390/f14122429>
21. Lee, H., Slatton, K. C., Roth, B. E., & Cropper Jr, W. P. (2010). Adaptive clustering of airborne LiDAR data to segment individual tree crowns in managed pine forests. *International Journal of Remote Sensing*, 31(1), 117-139. <https://doi.org/10.1080/01431160902882561>
22. Lee, K., van Leeuwen, W. J. D., & Falk, D. A. (2025). Quantifying Forest Structural and Functional Responses to Fire Severity Using Multi-Source Remotely Sensed Data. *Geographies*, 5(3), 30. <https://doi.org/10.3390/geographies5030030>
23. Lefsky, M. A., Cohen, W. B., Parker, G. G., & Harding, D. J. (2002). Lidar Remote Sensing for Ecosystem Studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and

global ecologists. *BioScience*, 52(1), 19-30. [https://doi.org/10.1641/0006-3568\(2002\)0520019:LRSFES2.0.CO;2](https://doi.org/10.1641/0006-3568(2002)0520019:LRSFES2.0.CO;2)

24. Ley 21.455 de 2022. Ley de marco de Cambio Climático. 13 de junio de 2022. D.O. No. 43.277. *Diario Oficial de la República de Chile*.
25. Li, Y., Wang, R., Shi, W., Yu, Q., Li, X., & Chen, X. (2022). Research on Accurate Estimation Method of Eucalyptus Biomass Based on Airborne LiDAR Data and Aerial Images Article. *Sustainability (Switzerland)*, 14(17), Article 10576. <https://doi.org/10.3390/su141710576>
26. Locatelli, B., Catterall, C. P., Imbach, P., Kumar, C., Lasco, R., Marín-Spiotta, E., Mercer, B., Powers, J. S., Schwartz, N., & Uriarte, M. (2015). Tropical reforestation and climate change: beyond carbon. *Restoration Ecology*, 23(4), 337-343. <https://doi.org/https://doi.org/10.1111/rec.12209>
27. Locatelli, B., Evans, V., Wardell, A., Andrade, A., & Vignola, R. (2011). Forests and Climate Change in Latin America: Linking Adaptation and Mitigation. *Forests*, 2(1), 431–450.
28. López, M., & Sandoval, S. (2023). Estimación de la densidad de rodal a partir de información LiDAR aérea integrando el método de masa y árbol individual en plantaciones de *Pinus radiata*. *BOSQUE*, 44(2), 377-386. <https://doi.org/10.4067/S0717-92002023000200377>
29. Martiník, A., Dobrovolný, L. & Hurt, V. (2016). "Potential of combined forest regeneration method on disturbed areas at lower altitudes." *Zpravy Lesnického Vyzkumu* 61(2): 125–131.
30. Mielcarek, M., Stereńczak, K., & Khosravipour, A. (2018). Testing and evaluating different LiDAR-derived canopy height model generation methods for tree height estimation. *International Journal of Applied Earth Observation and Geoinformation*, 71, 132-143. <https://doi.org/https://doi.org/10.1016/j.jag.2018.05.002>
31. Contribución Determinada a nivel Nacional (NDC) de Chile (2025). Gobierno de Chile. [NDC-2025-2035.pdf](#)
32. Nelson, C.R., Hallett, J.G., Romero Montoya, A.E., Andrade, A., Besacier, C., Boerger, V., Bouazza, K., Chazdon, R., Cohen-Shacham, E., Danano,

- D., Diederichsen, A., Fernandez, Y., Gann, G.D., Gonzales, E.K., Gruca, M., Guariguata, M.R., Gutierrez, V., Hancock, B., Innecken, P., Katz, S.M., McCormick, R., Moraes, L.F.D., Murcia, C., Nagabhatla, N., Pouaty Nzembialela, D., Rosado-May, F.J., Shaw, K., Swiderska, K., Vasseur, L., Venkataraman, R., Walder, B., Wang, Z., & Weidlich, E.W.A. (2024). Standards of practice to guide ecosystem restoration – A contribution to the United Nations Decade on Ecosystem Restoration 2021-2030. Rome, FAO, Washington, DC, SER & Gland, Switzerland, IUCN CEM. <https://doi.org/10.4060/cc9106en>
33. Özçelik, R., Diamantopoulou, M. J., Brooks, J. R., & Wiant, H. V. (2010). Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, 91(3), 742-753. <https://doi.org/https://doi.org/10.1016/j.jenvman.2009.10.002>
34. Özçelik, R., Diamantopoulou, M. J., Eker, M., & Gürlevik, N. (2017). Artificial Neural Network Models: An Alternative Approach for Reliable Aboveground Pine Tree Biomass Prediction. *Forest Science*, 63(3), 291-302. <https://doi.org/10.5849/FS-16-006>
35. Parresol, B. R. (1999). Assessing Tree and Stand Biomass: A Review with Examples and Critical Comparisons. *Forest Science*, 45(4), 573-593. <https://doi.org/10.1093/forestscience/45.4.573>
36. Pérez, C. (2022) Modelación paramétrica y no-paramétrica para estimar variables de estado de rodal usando información aérea LiDAR. Tesis Pregrado, Universidad de Concepción.
37. Popescu, S. C. (2007). Estimating biomass of individual pine trees using airborne lidar. *Biomass and Bioenergy*, 31(9), 646-655. <https://doi.org/https://doi.org/10.1016/j.biombioe.2007.06.022>
38. R Core Team (2024). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>
39. Roussel, J.-R., Auty, D., Coops, N. C., Tompalski, P., Goodbody, T. R. H., Meador, A. S., Bourdon, J.-F., de Boissieu, F., & Achim, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251, 112061

40. Sandoval, S., & Bustamante-Ortega, R. (2020). Estimation of Uncertainty in Airborne LiDAR Inventories Using Approaches Based on Bootstrapping-Pairs Methods. *Forests*, 11(12), 1305. <https://doi.org/10.3390/f11121305>
41. Sandoval-García, R., Jiménez-Pérez, J., Yerena-Yamallel, J. I., Aguirre-Calderón, O. A., Alanís-Rodríguez, E., & Gómez-Meza, M. V. (2022). Estrategias de restauración ecológica asociadas a reforestaciones de *Pinus cembroides* Zucc., en el Parque Nacional Cumbres de Monterrey. *Madera Y Bosques*, 28(2), e2822298. <https://doi.org/10.21829/myb.2022.2822298>
42. Schuh, M., Favarin, J. A. S., Marchesan, J., Alba, E., Fernando Berra, E., & Soares Pereira, R. (2020). Machine learning and generalized linear model techniques to predict aboveground biomass in Amazon rainforest using LiDAR data [Article]. *Journal of Applied Remote Sensing*, 14(3), Article 034518. <https://doi.org/10.1117/1.JRS.14.034518>
43. Silva, C. A., Hudak, A. T., Vierling, L. A., Loudermilk, E. L., O'Brien, J. J., Hiers, J. K., Jack, S. B., Gonzalez-Benecke, C., Lee, H., Falkowski, M. J., & Khosravipour, A. (2016). Imputation of Individual Longleaf Pine (*Pinus palustris* Mill.) Tree Attributes from Field and LiDAR Data. *Canadian Journal of Remote Sensing*, 42(5), 554-573. <https://doi.org/10.1080/07038992.2016.1196582>
44. Tiryaki, S., & Aydın, A. (2014). An artificial neural network model for predicting compression strength of heat-treated woods and comparison with a multiple linear regression model. *Construction and Building Materials*, 62, 102-108. <https://doi.org/https://doi.org/10.1016/j.conbuildmat.2014.03.041>
45. Tordesillas A. 2014. Estimación y evolución temporal de variables forestales con tecnología LiDAR en el valle de la Fuenfría (Cercedilla, Madrid) Trabajo Fin de Grado. Universidad Politécnica de Madrid. ETSI Montes, Forestal y del Medio Natural. Madrid, España. 142 p. https://oa.upm.es/30752/1/PFC_Alberto_Tordesillas_Torres.pdf
46. United Nations Environment Programme (2021). *Becoming #GenerationRestoration: Ecosystem restoration for people, nature and climate*. Nairobi
47. Vahedi, A. A. (2016). Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in

the Hyrcanian mixed-beech forests of Iran. *Biomass and Bioenergy*, 88, 66-76. <https://doi.org/https://doi.org/10.1016/j.biombioe.2016.03.020>

48. Vauhkonen, J., Ene, L., Gupta, S., Heinzl, J., Holmgren, J., Pitkänen, J., Solberg, S., Wang, Y., Weinacker, H., Hauglin, K. M., Lien, V., Packalén, P., Gobakken, T., Koch, B., Næsset, E., Tokola, T., & Maltamo, M. (2012). Comparative testing of single-tree detection algorithms under different types of forest. *Forestry: An International Journal of Forest Research*, 85(1), 27-40. <https://doi.org/10.1093/forestry/cpr051>
49. Veblen, T., Hill, R. & Read, J. (1996). *The ecology and biogeography of Nothofagus forests*. New Haven: Yale University Press.
50. Vergara-Díaz, G., & Herrera-Machuca, M. Á. (2021). Estimation and spatial analysis of aerial biomass and carbon capture in native forests in the south of Chile: County of Valdivia [Article]. *Revista Chapingo, Serie Ciencias Forestales y del Ambiente*, 27(1), 53–71. <https://doi.org/10.5154/R.RCHSCFA.2020.01.002>
51. Vierling, K. T., Vierling, L. A., Gould, W. A., Martinuzzi, S., & Clawges, R. M. (2008). Lidar: shedding new light on habitat characterization and modeling. *Frontiers in Ecology and the Environment*, 6(2), 90-98. <https://doi.org/https://doi.org/10.1890/070001>
52. Weiskittel, A. R., MacFarlane, D. W., Radtke, P. J., Affleck, D. L. R., Temesgen, H., Woodall, C. W., Westfall, J. A., & Coulston, J. W. (2015). A Call to Improve Methods for Estimating Tree Biomass for Regional and National Assessments. *Journal of Forestry*, 113(4), 414-424. <https://doi.org/10.5849/jof.14-091>
53. Zhao, D., Kane, M., Markewitz, D., Teskey, R., & Clutter, M. (2015). Additive Tree Biomass Equations for Midrotation Loblolly Pine Plantations. *Forest Science*, 61(4), 613-623. <https://doi.org/10.5849/forsci.14-193>
54. Zhao, K., Popescu, S., & Nelson, R. (2009). Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. *Remote Sensing of Environment*, 113(1), 182-196. <https://doi.org/https://doi.org/10.1016/j.rse.2008.09.009>
55. Zulkiflee, N. I. M., Zaki, N. A. M., Razak, T. R., Omar, H., Tajudin, S., Narashid, R. H., Suratman, M. N., & Latif, Z. A. (2023). MACHINE LEARNING PREDICTION OF TROPICAL FOREST ABOVE-GROUND

BIOMASS ESTIMATION. Journal of Sustainability Science and Management, 18(12), 95-110. <https://doi.org/10.46754/jssm.2023.12.009>