

UNIVERSIDAD NACIONAL DE CAJAMARCA

FACULTAD DE CIENCIAS AGRARIAS

ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL



**“MEJORAS PREDICTIVAS EN LA RELACIÓN ENTRE EL VOLUMEN DEL FUSTE Y EL
DIÁMETRO DEL TOCÓN DE *Cedrelinga cateniformis* Ducke EN MARISCAL CÁCERES -
SAN MARTÍN”**

TESIS

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO FORESTAL

PRESENTADO POR EL BACHILLER

DEIBER TARRILLO ALARCÓN

ASESOR

M. Sc. ING. VITOLY BECERRA MONTALVO

JAÉN – PERÚ

2024

CONSTANCIA DE INFORME DE ORIGINALIDAD

1. Investigador:

Tarrillo Alarcón Deiber

DNI: 72307640

Escuela Profesional/Unidad UNC:

Ingeniería Forestal

2. Asesor:

Ing. M. Sc. Vitoly Becerra Montalvo

Facultad/Unidad UNC:

Ingeniería Forestal

3. Grado académico o título profesional

Bachiller

Título profesional

Segunda especialidad

Maestro

Doctor

4. Tipo de Investigación:

Tesis

Trabajo de investigación

Trabajo de suficiencia profesional

Trabajo académico

Título de Trabajo de Investigación: "Mejoras predictivas en la relación entre el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* Ducke en Mariscal Cáceres - San Martín"

5.

6. Fecha de evaluación: 27/01/2025

7. Software antiplagio: TURNITIN URKUND (ORIGINAL) (*)


8. Porcentaje de Informe de Similitud: 9 %

9. Código Documento: oid: 3117:423970065

10. Resultado de la Evaluación de Similitud:

APROBADO PARA LEVANTAMIENTO DE OBSERVACIONES O DESAPROBADO

Fecha Emisión: 27/01/2025

| |
|--|
| <i>Firma y/o Sello Emisor Constancia</i> |
|  _____ Ing. M. Sc. Vitoly Becerra Montalvo DNI: 27727452 |



ACTA DE SUSTENTACIÓN DE TESIS

En la ciudad de Jaén, a los **veinte** días del mes de **diciembre** del año dos mil veinticuatro, se reunieron en el **Ambiente de la Sala de Docentes de Ingeniería Forestal- Filial Jaén**, los miembros del Jurado designados por el Consejo de Facultad de Ciencias Agrarias, según Resolución de Consejo de Facultad N° 307- 2024-FCA-UNC, de fecha 17 de julio 2024, con el objeto, de evaluar la sustentación del trabajo de Tesis titulado: **"MEJORAS PREDICTIVAS EN LA RELACIÓN ENTRE EL VOLUMEN DEL FUSTE Y EL DIÁMETRO DEL TOCÓN DE *Cedrelinga cateniformis* Ducke EN MARISCAL CÁCERES - SAN MARTÍN"** ejecutado por el Bachiller en Ciencias Forestales, **Don DEIBER TARRILLO ALARCÓN**, para optar el Título Profesional de **INGENIERO FORESTAL**.

A las **dieciséis** horas y **treinta** minutos, de acuerdo a lo estipulado en el Reglamento respectivo, el Presidente del Jurado dio por iniciado el evento, invitando al sustentante a exponer su trabajo de Tesis y luego de concluida la exposición, el jurado procedió a la formulación de preguntas. Concluido el acto de sustentación, el Jurado procedió a deliberar, para asignarle la calificación. Acto seguido, el Presidente del Jurado anunció la **APROBACIÓN** por **UNANIMIDAD** con el calificativo de **quince (15)**; por tanto, el Bachiller queda expedito para el inicio de los trámites, para que se le otorgue el Título Profesional de Ingeniero Forestal.

A las **diecisiete** horas y **veinte** minutos del mismo día, el Presidente del Jurado dio por concluido el acto.

Jaén, 20 de diciembre de 2024.

Ing. M. Sc. Germán Pérez Hurtado
PRESIDENTE

Ing. M. Sc. Francisco Fernando Aguirre De Los Ríos
SECRETARIO

Ing. M. Cs. Leiver Flores Flores
VOCAL

Ing. M. Sc. Vitoly Becerra Montalvo
ASESOR

DEDICATORIA

A Dios, por guiarme en mi Camino y permitirme llegar hasta este momento tan importante de mi formación profesional.

A mi querido padre Rocendo Tarrillo Torres y mi adorable madre María Maifa Alarcón Vásquez, quienes son el pilar fundamental de lo que soy, son ellos el mayor apoyo incondicional que recibo, razón para seguir adelante y ser el orgullo de ellos, quienes, además, me han inculcado valores que hoy en día me dio fortaleza y los ms sabios consejos para mi formación como profesional, logrando cumplir la promesa de esta anhelada meta.

A mis hermanas, Ana Cecilia Salazar Alarcón y Lucy Tarrillo Alarcón, que siempre fueron el mejor ejemplo y motivación de seguir adelante y ser parte fundamental en la formación académica y su apoyo incondicional en concretar mis objetivos.

Deiber

AGRADECIMIENTO

A Dios: Por la Gran bendición, de dejarme culminar esta investigación.

De una manera muy especial a mi asesor, M. Sc. Ing. Vitoly Becerra Montalvo, por brindarme en todo momento el asesoramiento correspondiente y el apoyo en poder concertar la investigación.

Al Ing. Willan Nolver Silva Silva Compañero de trabajo, por su apoyo brindado para desarrollar esta presente investigación.

A mis padres por siempre estar de mi lado en los buenos y malos momentos tiempos así mismo tengo que agradecer a mis hermanas por su apoyo incondicional.

A todas las personas que me apoyaron e hicieron posible que el trabajo se realice con éxito, en especial a aquellos que nos abrieron las puertas y compartieron sus conocimientos.

Deiber

ÍNDICE DE CONTENIDOS

| | |
|---|------|
| DEDICATORIA | ii |
| AGRADECIMIENTO | iii |
| ÍNDICE DE CONTENIDOS | iv |
| ÍNDICE DE TABLAS | vi |
| ÍNDICE DE FIGURAS | vii |
| RESUMEN | viii |
| ABSTRAC | ix |
| CAPÍTULO I: INTRODUCCIÓN | 10 |
| CAPÍTULO II: REVISIÓN BIBLIOGRÁFICA | 13 |
| 2.1. Antecedentes de la investigación | 13 |
| 2.2. Bases teóricas | 14 |
| 2.2.1. Descripción de la especie de <i>Cedrelinga cateniformis</i> Ducke | 14 |
| 2.2.2. Manejo forestal sostenible en la especie de <i>Cedrelinga cateniformis</i> | 15 |
| 2.2.3. Métodos convencionales de medición del volumen | 16 |
| 2.2.4. Definición del tocón del árbol | 17 |
| 2.2.5. Importancia de la relación entre el volumen y diámetro del tocón | 17 |
| 2.2.6. Importancia de la relación entre el diámetro a la altura del pecho y el diámetro del tocón | 17 |
| 2.2.7. Redes neuronales artificiales en la ingeniería forestal | 18 |
| 2.3. Definición de términos básicos | 24 |
| CAPÍTULO III: MARCO METODOLÓGICO | 27 |
| 3.1.1. Ubicación política de la Concesión | 27 |
| 3.1.2. Ubicación geográfica de la Concesión | 29 |
| 3.1.3. Ubicación y extensión de las Parcelas de Corta | 29 |
| 3.1.4. Hidrografía y fisiografía | 29 |
| 3.2. Tipo y diseño de investigación | 30 |
| 3.2.1. Unidad de análisis | 30 |
| 3.2.2. Fuentes, técnicas e instrumentos de recolección de datos | 30 |
| 3.2.3. Validación y prueba de confiabilidad | 30 |
| 3.2.4. Procedimiento de la investigación | 30 |
| 3.2.5. Aspectos éticos para considerar | 35 |
| 3.2.6. Presentación de información | 35 |
| CAPÍTULO IV: RESULTADOS Y DISCUSIÓN | 37 |
| 4.1. Análisis de los datos | 37 |
| 4.1.1. Análisis del Inventario Forestal | 37 |
| 4.1.2. Análisis de Consistencia de Datos del Trozado Forestal | 38 |
| 4.2. Análisis de índice de competencia | 42 |

| | | |
|--|--|----|
| 4.3. | Descripción de los datos climáticos | 47 |
| 4.4. | Análisis de Modelamiento | 49 |
| 4.4.1. | Análisis del Modelo Potencial | 49 |
| 4.4.2. | Análisis de las Redes Neuronales Artificiales | 52 |
| 4.4.3. | Análisis comparativo de las predicciones por el modelo potencial y las redes neuronales artificiales | 55 |
| 4.5. | Discusión | 57 |
| CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES | | 61 |
| 5.1. | Conclusiones | 61 |
| 5.2. | Recomendaciones | 62 |
| CAPÍTULO VI: REFERENCIAS BIBLIOGRÁFICAS | | 63 |
| CAPÍTULO VII: ANEXO | | 68 |

ÍNDICE DE TABLAS

| | | |
|----------|---|----|
| Tabla 1 | Ubicación política de la concesión forestal maderable N° 22-SAM/C-J-017-03 | 27 |
| Tabla 2 | Coordenadas UTM de la concesión forestal maderable N° 22-SAM/C-J-017-03 | 28 |
| Tabla 3 | Área y ubicación de las parcelas de Corta | 28 |
| Tabla 4 | Características dendrometrías promedio de especies arbórea encontradas en la base de datos de la concesión 1 | 37 |
| Tabla 5 | Características dendrometrías promedio de especies arbórea encontradas en la base de datos de la concesión 2 | 38 |
| Tabla 6 | Análisis estadístico del diámetro del tocón y volumen de datos recopilados en la base de datos de la concesión 1 | 39 |
| Tabla 7 | Análisis estadístico del diámetro del tocón y volumen de datos recopilados en la base de datos de la concesión 2 | 40 |
| Tabla 8 | Tabla 8. Análisis de índices de competición entre especies arbóreas en la base de datos de la concesión 1 | 43 |
| Tabla 9 | Análisis de índices de competición entre especies arbóreas en la base de datos de la concesión 2 | 45 |
| Tabla 10 | Registro mensual y anual de condiciones climáticas en el área de la concesión 1 | 47 |
| Tabla 11 | Registro mensual y anual de condiciones climáticas en el área de la concesión 2 | 48 |
| Tabla 12 | Comparación de los indicadores estadísticos de la estimación y la predicción del modelo de regresión potencial | 50 |
| Tabla 13 | Desempeño de los indicadores estadísticos de 30 modelos de redes neuronales artificiales en predicciones de volumen de árboles | 54 |
| Tabla 14 | Comparación del desempeño de los indicadores estadísticos entre modelos de redes neuronales artificiales y modelo potencial en predicciones de volumen de árboles | 55 |

ÍNDICE DE FIGURAS

| | | |
|----------|---|----|
| Figura 1 | Mapa de ubicación de la concesión forestal maderable N° 22-SAM/C-J-017-03 | 28 |
| Figura 2 | Implementación de la estrategia de validación para evaluar el desempeño estadístico del modelo desarrollado por la concesión 1 | 33 |
| Figura 3 | Dispersión de la ración del diámetro del tocón y el volumen provenientes de la base de datos de la concesión 1 y concesión 2 | 42 |
| Figura 4 | Mapa de dispersión de las especies en el entorno de la concesión 1 | 44 |
| Figura 5 | Mapa de dispersión de las especies en el entorno de la concesión 2 | 46 |
| Figura 6 | Relación entre el diámetro del tocón y el volumen con su línea de tendencia potencial de la base de datos de la concesión 1 | 49 |
| Figura 7 | Correlación entre el volumen observado y estimado, base de datos de la concesión 1 y 2 | 51 |
| Figura 8 | Distribución de las clases de error para los valores estimados y predictivos del modelo potencial | 52 |
| Figura 9 | Distribución de las clases de error para los valores predictivos de la red neuronal artificial seleccionada y el modelo potencial | 57 |

RESUMEN

El objetivo del estudio fue mejorar las predicciones sobre la relación entre el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke en Mariscal Cáceres - San Martín. Se realizó una investigación con dos fases. En la primera, se empleó un modelo potencial con datos de dos concesiones forestales, utilizando una para estimación y otra para validación. En la segunda fase, se aplicaron técnicas de redes neuronales artificiales (RNA) integrando datos climáticos e índices de competencia para mejorar las predicciones. Se exploraron múltiples algoritmos y combinaciones de variables, generando 30 modelos de RNA. El mejor modelo de RNA (RNA26) se comparó con el modelo potencial, mostrando que, este último tenía una correlación ligeramente superior y un error relativo más bajo, el RNA26 genera mayor proporción de predicciones precisas en la clase de error de 0%, por lo que RNA ofrece predicciones más cercanas a la realidad. Se demostró la utilidad de las RNA al incorporar diversas variables. Se concluyó que la inclusión de variables dasométricas, climáticas e índices de competencia en el desarrollo de redes neuronales permitió capturar una gama más amplia de factores influyentes en la relación entre el volumen del fuste y el diámetro del tocón del Tornillo. Se sugiere la implementación de un monitoreo continuo de diversas variables, como las dendrométricas, climáticas, edáficas y topográficas, esencial para comprender las complejas interrelaciones en los ecosistemas forestales.

Palabras clave: Redes neuronales artificiales, volumen, diámetro del tocón, validación predictiva.

ABSTRAC

The objective of the study was to improve predictions on the relationship between stem volume and stump diameter of *Cedrelinga cateniformis* Ducke in Mariscal Cáceres - San Martín. A two- phase investigation was carried out. In the first, a potential model was used with data from two forest concessions, using one for estimation and the other for validation. In the second phase, artificial neural network (ANN) techniques were applied, integrating climatic data and competition indices to improve predictions. Multiple algorithms and combinations of variables were explored, generating 30 ANN models. The best ANN model (ANN26) was compared with the potential model, showing that, the latter had slightly higher correlation and lower relative error, ANN26 generates higher proportion of accurate predictions in the 0% error class, thus ANN provides predictions closer to reality. The usefulness of ANN was demonstrated by incorporating several variables. It was concluded that the inclusion of dasometric, climatic and competition index variables in the development of neural networks allowed capturing a wider range of influential factors in the relationship between stem volume and stump diameter of Tornillo. It is suggested the implementation of a continuous monitoring of several variables, such as dendrometric, climatic, edaphic and topographic variables, essential to understand the complex interrelationships in forest ecosystems.

Keywords: Artificial neural networks, volume, stump diameter, predictive validation.

CAPÍTULO I

INTRODUCCIÓN

Dentro del campo de modelamiento forestal, los investigadores manejan los términos de estimaciones, predicciones, pronosticaciones y proyecciones. Estos cuatro términos a veces son utilizados en un lenguaje no técnico como iguales; sin embargo, existen amplia diferencia en entre ellos. Una estimación representa el estado actual de un individuo o población forestal, una predicción representa el estado actual de un individuo o población forestal que no representa la proveniencia de los datos, un pronóstico representa un estado aleatorio a grandes rasgos de un individuo o población forestal y una proyección representa un estado futuro de un individuo o población forestal (Campos & Leite, 2017; Goycochea Casas, 2021). Otros autores definen a la predicción como el cambio de tamaño de un individuo o población a lo largo del tiempo (Burkhardt & Tomé, 2012; Castro et al., 2013). Cabe mencionar que un mismo modelo matemático se puede utilizar para estimar y predecir mas no para proyectar. Para identificar un modelo de proyección, se tienen que observar que el modelo debe presentar como variable independiente a la variable dependiente futura, un ejemplo claro es el modelo de Clutter, que es un modelo explícitamente para proyecciones (Casas Fardin et al., 2022).

La aplicación de modelos matemáticos al campo forestal se viene dando desde los años 60 hasta la actualidad; sin embargo, su aplicación como modelo predictivo es un enfoque de estudio y desafiante para los investigadores, por el simple hecho de que los bosques representan una estructura super compleja por la gran cantidad de variables interconectadas entre ellos mismos. Por ejemplo, el modelo de Schumacher y Hall $LnV = \beta_0 + \beta_1 LnDAP + \beta_2 LnH + e$; es uno de los modelos más aplicados para estimaciones volumétricas (Schumacher & Hall, 1933). Este modelo establece una relación entre el volumen (V), diámetro a la altura del pecho (DAP) y altura del árbol (H), es decir $V = f(DAP, H)$. En el modelo se observa que utiliza como variables independientes a las variables mensurables o dasométricas de un árbol, que ciertamente es la relación más importante y representativa del volumen de un árbol, pero si el modelo se aplicaría como modelo predictivo, se estaría asumiendo que un estado de un bosque es la misma para otro estado de bosque. Esta consideración en la práctica no es lo mismo y más aún si se considera un bosque primario.

Así como el modelo de Schumacher y Hall (1993), la gran mayoría de los modelos aplicados en el campo forestal solo consideran variables dasométricas, de esta manera su correcta

utilidad es para estimaciones más que para predicciones, lo que perjudica su amplitud y aplicación del modelo.

Otro ejemplo notable es el modelo potencial, ampliamente empleado en la modelación forestal debido a que la relación entre el diámetro y el volumen de un árbol se expresa matemáticamente mediante la fórmula $V = \beta_0 DAP^{\beta_1}$ (Campos & Leite, 2017; S). Este modelo simplifica las variables dasométricas a un solo parámetro, el diámetro, lo que conlleva ventajas y desventajas en su aplicación. Una de las ventajas es la facilidad de medir el diámetro de un árbol; sin embargo, su utilidad en el modelado se limita a estimaciones exclusivas para el individuo medido, ya que, en la práctica al utilizarlo como un modelo de predicción, surge ciertas violaciones de las suposiciones estadísticas, siendo engañosas y tendenciosas, que perjudican al modelador para tomar decisiones.

Según el Informe de Evaluación de Recursos Forestales Mundiales, en el Perú se ha reducido en un preocupante 56.51 % el área boscosa de su superficie terrestre, alcanzando 1719.43 (1000 ha) entre 2010 y 2020 (SERFOR, 2020). Los bosques primarios en este país enfrentan anualmente niveles alarmantes de pérdida de cobertura boscosa debido a la deforestación, siendo el año 2021 testigo de la tasa más alta en las últimas dos décadas (Sierra Praeli, 2021). Ante esta grave situación, surge la consideración del uso del modelo potencial como una opción para predecir la pérdida de volumen debido a los cortes ilegales, dado que en estos casos apenas se encuentran registros de diámetros de tocones en el campo. Este modelo se basa exclusivamente en el diámetro, el cual podría ser sustituido por el diámetro del tocón de un árbol. No obstante, sirve como fundamento para la implementación de otras técnicas que incorporan múltiples variables, permitiendo una predicción más completa y precisa de un ecosistema boscoso.

Diversos investigadores están trabajando para resolver problemas de predicciones, estableciendo relaciones entre variables coherentes a las existentes de un bosque. Una alternativa es establecer modelamiento no solo considerando variables dasométricas, sino también variables externas o abióticas, tales como climáticas, edáficas, índices de competencia, índices de diversidad, altitudes, entre otros, en que utilizar técnicas de regresión es demasiado complejo, conllevando a utilizar otras técnicas de modelamiento tal como las redes neuronales artificiales.

Las variables abióticas son importantes porque pueden influir significativamente en el

crecimiento y la supervivencia de los árboles en los ecosistemas forestales. Por ejemplo, los cambios en la radiación solar pueden alterar el crecimiento y la distribución de diferentes especies de árboles. Sin embargo, cuantificar el efecto de estas variables mediante métodos de campo directos puede ser laborioso y consumir mucho tiempo, por lo que el desarrollo de modelos analíticos y predictivos, como el modelo de red neuronal artificial, es una alternativa para la integración de diversas variables a un modelo (Bayat et al., 2019).

El presente trabajo, se estableció una relación entre volumen y el diámetro del tocón en la especie de *Cedrelinga cateniformis* (Ducke) Ducke en un bosque primario, en que se aplicó la técnica de modelamiento de redes neuronales artificiales con inclusión de variables dasométricas, climáticas e índice de competición, con el fin de mejorar las predicciones y establecer datos para un manejo forestal sustentable.

Las hipótesis que se plantearon fueron: Hipótesis nula, Las predicciones volumétricas son mejoradas en relación con el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke mediante la consideración de las variables climáticas e índices de competición en Mariscal Cáceres, San Martín. Hipótesis alternativa, Las predicciones volumétricas no son mejoradas en relación con el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke mediante la consideración de las variables climáticas e índices de competición en Mariscal Cáceres, San Martín.

El objetivo general fue Mejorar las predicciones en la relación entre el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke en Mariscal Cáceres -San Martín. Mientras que los objetivos específicos fueron: Realizar un análisis del Inventario Forestal para identificar tendencias y patrones en la distribución de especies y densidades poblacionales del bosque. Examinar el índice de competición entre especies vegetales en el área de estudio para comprender las relaciones competitivas entre ellas. Determinar los algoritmos utilizados para optimización de la red neuronal que se puedan ajustar en la relación del volumen y diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke en Mariscal Cáceres -San Martín. Evaluar y analizar la eficacia del Modelo Potencial y las Redes Neuronales Artificiales en la predicción de variables forestales clave, realizando un análisis comparativo entre las predicciones generadas por ambos modelos.

CAPÍTULO II

REVISIÓN BIBLIOGRÁFICA

2.1. Antecedentes de la investigación

Un estudio reciente se mantiene centrado en la relación entre el diámetro del tocón y el volumen (Hung et al., 2021), en este caso para árboles de acacia, en que los autores establecieron una serie de modelos muy conocidos en la literatura, tales como una relación lineal, logarítmica, inversa, cuadrática, cúbica, exponencial, potencial, etc., llegando a la conclusión que la función potencial, $V = \beta_0 * DT^{\beta_1}$, es el mejor modelo para simular la relación entre el DT y el V , así mismo como mejor modelo para las predicciones volumétricas.

Otro estudio realizó la predicción del diámetro normal, altura y volumen a partir del diámetro del tocón, estableciendo modelos matemáticos lineales y no lineales para ocho especies forestales con el fin del control y supervisión del manejo forestal para cuantificar cortas clandestinas. Los modelos empleados mostraron buenos estimadores estadísticos indicando que fueron válidos para las predicciones (Cuevas et al., 2017).

Investigadores también establecen una relación alométrica entre la altura total y el diámetro normal de *Bursera simaruba*, en que los autores manifiestan que las relaciones empleadas en su estudio podrán ser empleadas para evaluar cortas clandestinas cuando el único dato posible de medir es el diámetro de tocón, siendo como variable independiente de la relación del modelo empleado (Hernández-Ramos et al., 2018).

También existe estudios realizados utilizando redes neuronales artificiales para modelar la relación entre el diámetro a la altura del pecho (DAP) y el diámetro del tocón. Al comparar con un modelo de regresión, el R^2_{adj} con aumentó de 0,7377 %. Los autores concluyen la técnica aplicada es una alternativa de modelado para que los administradores forestales predigan la información requerida sobre DAP para el manejo de los bosques (Şenyurt et al., 2020).

Un estudio destaca la importancia de los factores bióticos y abióticos en la determinación de la probabilidad de supervivencia de los árboles. Al comprender la relación entre estos factores y la supervivencia de los árboles, los gestores forestales pueden desarrollar estrategias más eficaces para el manejo forestal sostenible, como el aclareo para reducir la competencia y mejorar las condiciones de crecimiento. Además, el uso de redes neuronales artificiales proporciona una herramienta poderosa para predecir la supervivencia y mortalidad de los

árboles, lo que puede ayudar a informar las decisiones de manejo forestal y mejorar la salud y productividad a largo plazo de los ecosistemas forestales (Bayat et al., 2019; Rocha et al., 2018).

Un estudio realizó mediciones del diámetro y altura del tocón para emplear un modelo matemático para la especie del algarrobo (*Prosopis pallida*) con el fin de proyectar el volumen aprovechado de la madera ilegal en la concesión de la Universidad de Tumbes. El modelo adecuado fue el potencial con un coeficiente de determinación mayor al 90 % (Zarate, 2021).

En un estudio reciente, destacaron la importancia de las variables climáticas para comprender el crecimiento y desarrollo de *Guazuma crinita* Mart. en la Amazonía peruana. El estudio utilizó variables agroclimáticas para analizar la relación entre el crecimiento de la especie y las condiciones climáticas de la región. Las variables incluyeron presión superficial, temperatura, humedad, velocidad del viento, humedad del suelo y precipitación. Los resultados del estudio pueden utilizarse para mejorar las prácticas de manejo forestal e informar los esfuerzos de conservación en la Amazonía peruana y otras regiones con condiciones ecológicas similares. El estudio también destaca la importancia de comprender las complejas interacciones entre los árboles y su entorno climático para una gestión forestal sostenible. La importancia de esta investigación radica en su contribución al desarrollo de modelos precisos y eficientes para el manejo y conservación forestal. Los modelos desarrollados en esta investigación pueden servir como herramientas valiosas para los gestores forestales, ayudándoles a tomar decisiones informadas que promuevan el crecimiento y la supervivencia de *Guazuma crinita* Mart. en la Amazonía peruana (Casas et al., 2022).

2.2. Bases teóricas

2.2.1. Descripción de la especie de Cedrelinga cateniformis (Ducke) Ducke

Cedrelinga cateniformis (Ducke) Ducke, conocida popularmente como Chuncho o Tornillo, es un árbol emblemático de la región amazónica, encontrándose en países como Ecuador, Perú y posiblemente en otras áreas de la cuenca amazónica. Esta especie arbórea no solo es de interés en la industria forestal por la calidad de su madera, sino también en sistemas agroforestales debido a su potencial para el desarrollo sostenible de la región. De hecho, ha sido objeto de diversos estudios de modelamiento de crecimiento en plantaciones en la región amazónica, destacando así su importancia tanto económica como ecológica (Baluarte-Vásquez & Alvarez-Gonzales, 2015).

Desde el punto de vista *taxonómico*, *Cedrelinga cateniformis* pertenece al Reino Plantae, la División Magnoliophyta, la Clase Magnoliopsida, el Orden Fabales, la Familia Fabaceae y la Subfamilia Mimosoideae. Esta especie se caracteriza por su robustez y majestuosidad, alcanzando alturas de hasta 40 metros y un diámetro de tronco de hasta 1,8 metros. Su tronco recto y cilíndrico, así como su corteza grisácea y fisurada, son rasgos distintivos. En cuanto a su distribución, se encuentra en hábitats específicos como los bosques húmedos tropicales de tierras bajas hasta los 750 metros de altitud. Prefiere suelos arcillosos y bien drenados, siendo común encontrarlo en riberas de ríos y zonas pantanosas (Missouri Botanical Garden, 2024). En el Perú, se distribuye en altitudes que van desde los 120 hasta los 800 metros sobre el nivel del mar. Se adapta a una amplia gama de condiciones climáticas, con temperaturas que oscilan entre los 15 °C y los 38 °C, y niveles de precipitación que van desde 2 500 mm hasta 3 800 mm. Este árbol se encuentra típicamente en bosques primarios y en suelos arcillosos de carácter ácido (Campos, 2009).

La madera de *Cedrelinga cateniformis* es altamente valorada por su calidad, presentando un color marrón claro, una textura fina y una buena resistencia. Esta madera se emplea en la construcción, la fabricación de muebles, instrumentos musicales, entre otros usos. Además, la especie tiene aplicaciones medicinales, utilizando la corteza y las hojas para tratar diversas enfermedades, así como en la extracción de alcanfor a partir de su corteza (Vásquez, 2023).

En plántulas de *Cedrelinga cateniformis* (tornillo) para determinar su efecto en el crecimiento, sobrevivencia y estado fitosanitario en un vivero, el tratamiento más efectivo consistía en tierra agrícola más una dosis de superfosfato triple, demostrando un mayor crecimiento en diámetro y altura en comparación con el grupo de control. Además, a menor dosis de fertilizante, la sobrevivencia de las plántulas fue mayor, sugiriendo que dosis más altas de superfosfato triple pueden resultar en una mayor mortalidad de las plántulas (Vásquez, 2023).

2.2.2. Manejo forestal sostenible en la especie de *Cedrelinga cateniformis*

La historia del manejo de *Cedrelinga cateniformis* se remonta a la época precolombina, cuando los pueblos indígenas utilizaban su madera para la construcción de viviendas, herramientas y otros objetos. En la época colonial, la explotación de *Cedrelinga cateniformis* se intensificó para la producción de madera aserrada y muebles. Sin embargo, esta explotación no se basaba en criterios de sostenibilidad, lo que llevó a la deforestación y degradación de los bosques amazónicos. A partir de la década de 1970, comenzó a surgir la

preocupación por la sostenibilidad del manejo forestal. En este contexto, se iniciaron proyectos piloto de manejo forestal sostenible (MFS) en *Cedrelinga cateniformis*. Según el modelo bioeconómico de Manejo Forestal Sostenible (MFS) de tiempo discreto, una herramienta de planificación que considera aspectos biológicos y económicos para el manejo forestal sostenible (MFS) se determina que para la *Cedrelinga cateniformis* el aprovechamiento óptimo para maximizar los beneficios económicos se realiza en un ciclo de 25 años. Esto resulta en beneficios económicos de 513.95 USD por hectárea en un período de planificación de 50 años (Castellanos & Marco, 2023).

La *Cedrelinga cateniformis*, experimenta un aumento promedio de 1 cm en su diámetro a la altura del pecho (DAP) por año (Baluarte-Vásquez & Alvarez-Gonzales, 2015), alcanzando su máximo volumen comercial entre los 90 y 100 cm de diámetro en aproximadamente 80 años. Esta especie exhibe tasas de crecimiento superiores a otras especies nativas, llegando al diámetro mínimo de corte de 50 cm a una edad media de 61 años (Brienen & Zuidema, 2006).

2.2.3. Métodos convencionales de medición del volumen

Los métodos convencionales para medir el volumen de un árbol se dividen en dos categorías principales: directos e indirectos. En los métodos directos, la cubicación es común. Consiste en medir la altura total del árbol (H) y el diámetro a la altura del pecho (DAP), luego se estima el volumen del fuste utilizando fórmulas geométricas como la del cilindro o el cono, y se calcula el volumen de las ramas y la copa utilizando métodos de aproximación, sumando todo para obtener el volumen total. También se emplean formas volumétricas que utilizan tablas o ecuaciones preestablecidas que relacionan el DAP y la altura con el volumen del árbol, aunque pueden ser menos precisas que la cubicación (Campos & Leite, 2017).

Los métodos indirectos incluyen la relación altura-diámetro, donde se utiliza una ecuación alométrica para estimar el volumen del árbol basándose en el DAP y la altura total, útil cuando no se puede acceder a la copa. Otro método es el uso de modelos de biomasa que relacionan la biomasa del árbol con variables como el DAP, la altura y la densidad de la madera, convirtiendo la biomasa en volumen mediante un factor de conversión, aunque requiere mediciones adicionales (Baluarte-Vásquez & Alvarez-Gonzales, 2015; Campos & Leite, 2017). Los equipos necesarios incluyen cinta métrica, clinómetro, telémetro, formularios de medición y software para cálculos volumétricos. Es fundamental considerar estos aspectos para obtener mediciones precisas y útiles en el manejo forestal (Soares et al., 2011).

2.2.4. Definición del tocón del árbol

El término "tocón" se refiere a la porción del tronco de un árbol que permanece en la tierra después de haber sido cortado o caído. Esta sección proporciona información relevante sobre el diámetro y la altura de los tocones, así como su importancia en diversas aplicaciones (Diéguez-Aranda et al., 2003).

El diámetro del tocón se define como la distancia de un lado al otro del tocón, pasando por su centro. Esta medida se toma típicamente a una altura estándar del suelo, que puede ser de 10 cm, 20 cm o 30 cm. Por otro lado, la altura promedio del tocón varía según varios factores, incluida la especie del árbol, la altura a la que se cortó el árbol y las condiciones del suelo. En general, esta altura oscila entre 10 cm y 50 cm, sin embargo, algunos estudios consideran que un tocón se forma cuando la sección del tronco tiene un diámetro superior a 10 cm (Guzmán-Santiago et al., 2023).

2.2.5. Importancia de la relación entre el volumen y diámetro del tocón

Cuando un árbol es cortado se observa que se deja una porción de madera llamada tocón. La mensuración del tocón, especialmente el diámetro, es de suma importancia debido que alberga mucha información importante que puede ayudar a entender las siguientes peculiaridades (Diéguez-Aranda et al., 2003; Parresol, 1998):

- ✓ Evaluar la madera aprovechada en un corte final o raleo.
- ✓ Verificar las prácticas de cosecha después de la remoción de árboles.
- ✓ Determinar la pérdida de volumen resultante de los cortes ilícitos.
- ✓ Evaluar los daños resultantes de condiciones ambientales adversas.
- ✓ Rastrear la historia del corte para evaluar las prácticas silvícolas.

De acuerdo con Campos y Leite (2017) la relación entre el volumen y diámetro del tocón son necesarias para cuando el cortador de madera a cruzado los límites de la propiedad o cuando han removido árboles que no estaban marcados para talar. Las mediciones de tocones en áreas de muestra también se pueden usar para estimaciones estatales o regionales del volumen de madera cortada anualmente, en lugar de la encuesta habitual de producción de madera.

2.2.6. Importancia de la relación entre el diámetro a la altura del pecho y el diámetro del tocón

El diámetro normal es una de las variables importantes dentro de la mensuración forestal. Es una variable bien requerida para estudios de inventario, estructura y dinámica, crecimiento y

producción forestal por su fácil mensuración, que prácticamente casi todos los modelos matemáticos la incluyen como variable independiente (Campos & Leite, 2017).

La relación entre el diámetro normal y el diámetro del tocón es necesaria cuando el modelador utiliza modelos matemáticos en que el diámetro normal es una variable independiente para una predicción volumétrica. Por lo general la gran mayoría de los modelos volumétricos utilizan el diámetro normal en vez del diámetro de tocón, de aquí su importancia de establecer la relación entre ambas variables (Diéguez-Aranda et al., 2003). La relación de estas dos variables siempre va a ser lineal, es decir, $DAP = \beta_0 + DT * \beta_1$, en que DAP es el diámetro a la altura del pecho y DT es el diámetro del tocón. Establecida la relación del DAP y DT , se pueden establecer predicciones volumétricas utilizando cubicaciones locales o modelos matemáticos (Bylin, 1982; Campos & Leite, 2017; Soares et al., 2011).

2.2.7. Redes neuronales artificiales en la ingeniería forestal

Una red neuronal se puede definir como un conjunto de neuronas artificiales distribuidas en capas conectadas de una forma específica para desarrollar una determinada tarea. Esta red neuronal fue motivada por el funcionamiento del cerebro humano en su procesamiento de informaciones, pudiéndose organizar diferentes elementos y reconocimientos de patrones, más rápido que un computador computacional (Aggarwal, 2018; Montesinos López et al., 2022).

A lo largo de tiempo se han empleado adaptar a las ciencias forestales diferentes algoritmos y técnicas de machine learning, tales como random forest (de Oliveira et al., 2021; Liu et al., 2020; Pereira et al., 2021), support vector machines (García Nieto et al., 2012), técnica de boosted (Gonçalves et al., 2021) y redes neuronales artificiales (Casas, Fardin, et al., 2022; Casas, Gonzáles, et al., 2022; Rocha et al., 2018).

El uso de redes neuronales en las ciencias forestales se ha vuelto muy común por ser una técnica potente para resolver problemas, especialmente en las áreas de modelación matemáticamente, por motivos que se pueden utilizar muchas otras variables, en especial características climáticas, edáficas y fisiográficas (Aline et al., 2018). Por lo general, las redes neuronales artificiales presentan mejor precisión en sus predicciones que utilizando los modelos matemáticos tradicionales.

Dentro de la mensuración forestal, las redes neuronales han presentado estimaciones altamente precisas en las predicciones de altura (Casas, Gonzáles, et al., 2022; Da Rocha et al., 2021; Silva et al., 2020; Vendruscolo et al., 2017), volumen (Casas, Fardin, et al., 2022; da Silva

Tavares Júnior et al., 2019; Freitas et al., 2020), afilamiento del fuste (da Cunha Neto et al., 2019).

Redes neuronales artificiales aplicado en las ciencias forestales

Las redes neuronales artificiales (RNA) han demostrado ser herramientas valiosas en la clasificación de patrones complejos y con alta variabilidad, superando la precisión de los métodos convencionales. Rodríguez et al. (2022) implementaron una metodología estructurada que incluyó tanto la recolección como el procesamiento de datos para evaluar la eficacia de las RNA en este ámbito. En la etapa de recolección y adecuación de información, utilizaron una imagen Landsat TM junto con un modelo de elevación digital (MED) proporcionado por el INEGI. A partir de estos insumos, generaron capas de exposición, pendiente y altitud, además de digitalizar información cartográfica relacionada con escurrimientos, edafología, geología y vegetación.

Durante el procesamiento de datos, construyeron una matriz compuesta por valores de componentes principales y diversas variables ambientales, como altitud, exposición, pendiente, distancia a escurrimientos, geología, edafología y vegetación. Utilizaron el software NeuroShell 2 para diseñar y entrenar una RNA con dos capas ocultas y funciones de activación tangencial hiperbólica y gaussiana.

En la fase de entrenamiento, la RNA final consistió en cuatro capas: nueve neuronas en la capa de entrada, 36 neuronas en cada capa oculta y una neurona en la capa de salida. Este diseño alcanzó un coeficiente de determinación (r^2) de 0,8617 y un coeficiente de correlación de 0,9283. Posteriormente, en la fase de prueba, se obtuvo un r^2 de 0,8514 y un coeficiente de correlación de 0,9227, destacando la clase de pastizal-matorral con un 93,99 % de sitios clasificados correctamente.

Las conclusiones del estudio subrayan que las RNA son altamente eficientes para clasificar patrones con gran variabilidad y pueden procesar una gran cantidad de datos casi en tiempo real una vez entrenadas. Además, esta metodología es versátil y puede aplicarse a problemas que requieran manejar extensos volúmenes de información, facilitando así una toma de decisiones más precisa en diversos contextos.

Las redes neuronales artificiales (RNA) continúan demostrando su eficacia en la clasificación de patrones complejos, como lo evidenció Silva et al. (2022) en su estudio realizado en un bosque estuarino de llanura aluvial en Itatupã, Pará, Brasil. En este trabajo, las RNA se

utilizaron específicamente para clasificar estratos forestales, empleando dos algoritmos de propagación resiliente (Rprop+ y Rprop-) en cuatro configuraciones distintas de variables de entrada. El proceso de entrenamiento y prueba de los modelos se llevó a cabo con el software R, y la evaluación de los resultados se realizó mediante una matriz de confusión.

Entre los resultados más destacados, los modelos con combinaciones de las variables altura total (HT), diámetro a la altura del pecho (DAP) y factor de forma (QF), así como HT y DAP o únicamente HT, utilizando el algoritmo Rprop+, alcanzaron un 100% de precisión en la clasificación de los estratos forestales. Estos modelos demostraron no solo una alta tasa de aprendizaje, sino también una confiabilidad y generalización significativas en los datos procesados. La variable HT fue identificada como la de mayor peso en el desempeño de la red neuronal, siendo clave para lograr la precisión observada.

En sus conclusiones, los autores resaltaron que los modelos de RNA con el algoritmo Rprop+ ofrecen una alta precisión para la clasificación de estratos forestales en entornos de llanura aluvial. Este enfoque no solo valida la relevancia de la variable altura total (HT) en la clasificación, sino que también demuestra la capacidad de las RNA para optimizar la planificación forestal y facilitar decisiones de manejo sostenible. Este estudio refuerza el potencial de las RNA como herramientas versátiles y efectivas en la gestión de recursos naturales.

Las redes neuronales artificiales (RNA) destacan como herramientas prometedoras en el ámbito de la estimación de variables forestales, como lo demostró dos Santos et al. (2018) en su estudio centrado en la especie *Couratari stellata*. Este trabajo comparó las estimaciones de volumen obtenidas mediante ecuaciones de regresión tradicionales y RNA, utilizando datos de cubicación rigurosa de 1 351 árboles con diámetros a la altura del pecho (DAP) mayores a 50 cm, recolectados en cuatro Unidades de Producción Anual (UPAs). Para seleccionar el modelo de regresión más adecuado, se emplearon el error cuadrático medio en porcentaje (RMSE %), la correlación de Pearson y el análisis gráfico de residuos porcentuales. Posteriormente, este modelo se comparó con la mejor red neuronal ajustada, utilizando las mismas métricas estadísticas.

Los resultados indicaron que ambos métodos presentaron un ajuste y precisión aceptables, pero las RNA se destacaron al mostrar un desempeño ligeramente superior. Esta ventaja se atribuye a su capacidad de aprender patrones complejos y generalizar el conocimiento

adquirido, lo que les permite ofrecer estimaciones más robustas y confiables.

En sus conclusiones, los autores recomendaron el uso de redes neuronales artificiales para la estimación del volumen de *Couratari stellata*, destacando su habilidad para superar las limitaciones de las ecuaciones de regresión tradicionales. Este enfoque refuerza el potencial de las RNA como herramientas innovadoras para mejorar la precisión en la gestión forestal y en la toma de decisiones relacionadas con el aprovechamiento sostenible de los recursos.

Las redes neuronales artificiales (RNA) y los autómatas celulares (AC) se han consolidado como herramientas efectivas para modelar dinámicas forestales complejas, como lo evidenció Reis et al. (2018) en su estudio realizado en la Floresta Nacional do Tapajós, Pará, Brasil. Este trabajo utilizó datos provenientes de inventarios forestales realizados entre 1975 y 2012 para proyectar la distribución diamétrica del bosque. La metodología incluyó el entrenamiento de 300 RNA con datos de parcelas permanentes, utilizándose posteriormente las RNA como regla de evolución para los AC.

Los resultados destacaron la precisión de las proyecciones obtenidas: las cinco mejores RNA lograron coeficientes de correlación superiores al 99 % y errores por debajo del 17 %. Además, las proyecciones mantuvieron la forma de la distribución diamétrica observada a lo largo del tiempo, sin diferencias significativas respecto a los datos reales. La técnica fue validada empleando información de parcelas permanentes, confirmando que las proyecciones seguían las tendencias dinámicas del bosque.

En sus conclusiones, los autores subrayaron la eficiencia de las RNA y AC para proyectar distribuciones diamétricas en la Amazonía, destacando su potencial aplicación en la toma de decisiones para el manejo forestal sostenible. Esto incluye la determinación de ciclos de corta e intensidades de aprovechamiento. Finalmente, recomendaron realizar investigaciones futuras que evalúen diferentes escenarios de corte, con el objetivo de mejorar aún más la precisión y utilidad de las proyecciones en contextos de manejo forestal.

Las redes neuronales artificiales (RNA) se han consolidado como herramientas avanzadas para modelar el crecimiento de árboles individuales en florestas naturales, como lo demuestra el estudio realizado en Viçosa, Minas Gerais (Castro et al., 2020). Durante un periodo de 14 años, se monitorearon diez parcelas permanentes en cinco ocasiones, generando un conjunto robusto de datos que permitió evaluar la eficiencia de las RNA en la proyección simultánea de variables clave: diámetro (dap), altura total (Ht) y altura del fuste (Hf). Los datos se dividieron en dos

grupos: uno para el entrenamiento de las redes neuronales (3 556 casos) y otro para la generalización (2 062 casos).

Se entrenaron dos tipos de redes neuronales, MLP (Perceptrón Multicapa) y RBF (Funciones de Base Radial), utilizando como variables de entrada diámetros y alturas observadas, índices de competencia, nivel de iluminación de las copas, calidad de la copa, grupo ecológico y familia botánica. Los resultados mostraron que ambas redes alcanzaron coeficientes de correlación superiores a 0,900 en la proyección de las tres variables, destacando su alta precisión. Sin embargo, las redes MLP evidenciaron un mejor poder de generalización en comparación con las RBF. Entre los factores más influyentes en las tasas de crecimiento, se identificaron el nivel de iluminación y la calidad de las copas.

El estudio concluyó que las RNA son herramientas altamente eficientes para proyectar simultáneamente el DAP, la altura total y la altura del fuste de árboles en florestas inequiáneas. Este enfoque simplifica el modelado y ofrece resultados precisos que pueden ser aplicados en la gestión sostenible de florestas naturales en Brasil. Además, el potencial de las RNA para la modelación del crecimiento forestal reafirma su utilidad en contextos de manejo forestal y planificación a largo plazo.

Las redes neuronales artificiales (RNA) han demostrado ser herramientas de gran precisión para la estimación de parámetros forestales complejos, como lo evidencia este estudio enfocado en la estimación del volumen de madera a partir del diámetro a la altura del pecho (DAP). Utilizando datos recopilados de múltiples especies de árboles, se entrenaron RNA diseñadas específicamente para mejorar la exactitud de las estimaciones de volumen de (Oliveira & Valente, 2021).

Los resultados destacaron que las RNA lograron estimaciones altamente precisas, superando en eficiencia y exactitud a los métodos tradicionales. Este desempeño resalta la capacidad de las RNA para modelar relaciones no lineales complejas entre las variables forestales y el volumen de madera.

En sus conclusiones, el estudio reafirma la eficacia de las RNA como herramientas innovadoras para la estimación del volumen de madera forestal. Su implementación no solo permite mejorar significativamente la gestión forestal, sino que también optimiza la planificación de recursos, favoreciendo una explotación más sostenible y eficiente de los ecosistemas forestales.

Las técnicas modernas de modelación como las Máquinas de Vectores de Soporte (MVS) y las Redes Neuronales Artificiales (RNA) ofrecen alternativas precisas y eficientes para la estimación de volúmenes forestales, como lo demuestra el estudio de Cordeiro et al. (2022). Esta investigación evaluó el desempeño de estas metodologías en plantaciones comerciales de eucalipto no desbastadas, ubicadas en cuatro municipios del estado de Amapá, Brasil. Los datos recolectados fueron divididos en un 80% para entrenamiento y un 20 % para validación, permitiendo una comparación detallada entre modelos volumétricos tradicionales y técnicas modernas basadas en MVS y RNA, utilizando variables dendrométricas como el diámetro a la altura del pecho (DAP) y la altura total.

Los resultados indicaron que tanto las MVS como las RNA superaron ligeramente a los métodos tradicionales en la estimación del volumen individual de los árboles. En el caso de las MVS, las configuraciones con funciones de Kernel radial (RBF) y lineal tipo II destacaron por su mayor precisión. Por parte de las RNA, se evaluaron configuraciones como Adaline, Perceptrón Multicapa (MLP) y Funciones de Base Radial (RBF), siendo esta última la que mostró un desempeño superior.

En sus conclusiones, el estudio subraya que las MVS y RNA son metodologías eficaces y estadísticamente confiables, representando una mejora respecto a los enfoques convencionales. Su flexibilidad y precisión las posicionan como herramientas prometedoras para aplicaciones en medición y manejo forestal, contribuyendo al desarrollo de estrategias más sostenibles y eficientes en la gestión de plantaciones comerciales.

Los algoritmos de aprendizaje automático han demostrado ser herramientas valiosas en la cartografía de susceptibilidad a deslizamientos, como lo evidenció el estudio de Daviran et al. (2023). Esta investigación comparó tres enfoques principales: Máquinas de Vectores de Soporte (SVM), Redes Neuronales Artificiales de Perceptrón Multicapa (MLP-ANN) y Bosques Aleatorios (RF), para identificar las áreas susceptibles a deslizamientos en la subcuenca de Taram-Khalkhal, al noroeste de Irán. El área de estudio, caracterizada por una alta incidencia de deslizamientos, permitió evaluar la precisión y robustez de estos algoritmos en un entorno desafiante.

Se consideraron quince factores predisponentes recopilados a partir de imágenes aéreas y encuestas de campo, integrados en los modelos para generar mapas de susceptibilidad. La validación de los resultados se realizó mediante matrices de confusión y curvas ROC. Entre los

tres algoritmos, RF obtuvo el mejor rendimiento, con un AUC de 0,93. Posteriormente, se utilizó un enfoque híbrido de Bosque Aleatorio Genético (GRF) para optimizar los hiperparámetros clave del modelo, como el número de árboles, divisiones y profundidad, logrando mejorar aún más su rendimiento.

El estudio concluyó que los algoritmos genéticos son herramientas efectivas para optimizar el desempeño de modelos de aprendizaje automático, maximizando su precisión y utilidad en aplicaciones como la cartografía de susceptibilidad a deslizamientos. Sin embargo, no se descarta las redes neuronales como herramienta alternativa en el estudio. Este enfoque no solo mejora la capacidad predictiva de los modelos, sino que también refuerza su aplicabilidad en la gestión y planificación de riesgos naturales en áreas vulnerables.

2.3. Definición de términos básicos

Bosque: Ecosistema en que predominan especies arbóreas en cualquier estado de desarrollo, cuya cobertura de copa supera el 10 % en condiciones áridas o semiáridas o el 25 % en circunstancias más favorables (OSINFOR, 2017, p. 7).

Manejo forestal: Actividades de caracterización, evaluación, investigación, planificación, aprovechamiento, reintroducción, repoblamiento, enriquecimiento, protección y control de hábitat de las poblaciones de fauna silvestre conducentes a asegurar la producción sostenible de bienes, la provisión sostenible de servicios y la conservación de la diversidad biológica (OSINFOR, 2017, p. 8).

Planificación para la gestión forestal: La planificación forestal y de fauna silvestre se enmarca en la política nacional forestal y de fauna silvestre, que constituye el documento guía del accionar forestal para asegurar el aprovechamiento sostenible y la conservación del recurso forestal y de fauna silvestre (OSINFOR, 2017, p. 8).

Troza: Sección o parte del fuste o tronco de un árbol libre de ramas, de longitud variable, obtenida por cortes transversales (Soares et al., 2011, P. 4).

Diámetro: Es la distancia existente entre dos puntos inscritos en la circunferencia del fuste y que además pasa por el centro del círculo formado por dicha sección (Soares et al., 2011, p. 2).

Tocón: Parte del tronco de un árbol que queda en el suelo unida a la raíz como resultado

del talado (Soares et al., 2011, p. 3).

Diámetro del tocón: Es el diámetro por debajo del dap y que es hallado cuando es removido o talado el árbol (Soares et al., 2011, p 3).

Estimación: Proceso de encontrar una aproximación sobre una medida (Soares et al., 2011).

Redes neuronales artificiales: Sistema computacional con conjunto de neuronas artificiales distribuidas en capas conectadas de una forma específica para desarrollar una determinada tarea. Son modelos matemáticos que intentan simular el funcionamiento del cerebro humano para resolver problemas de la vida real (Aggarwal, 2018; Montesinos López et al., 2022, p. 379).

Entrenamiento: Capacidad de aprendizaje de la red neuronal artificial. Aplicación de pasos ordenados que sean necesarios para sintonizar el relacionamiento existente entre las diversas variables que componen los datos con el objetivo de generalizar soluciones (Aggarwal, 2018; Montesinos López et al., 2022, p. 407).

Validación: Analizar la eficiencia y la aplicabilidad de la red neuronal. Generalización del conocimiento aprendido por parte del entrenamiento, posibilitando estimar soluciones que son desconocidas. Se analizan con indicadores estadísticos (Aggarwal, 2018; Montesinos López et al., 2022, p. 109).

Organización de datos: Conjunto de informaciones respecto a un proceso de entrenamiento, posibilitando el agrupamiento de patrones que presentan particularidades en común de los datos (Aggarwal, 2018; Montesinos López et al., 2022, p. 35).

Algoritmo: Son un conjunto finito de pasos elementales que se aplican sistemáticamente hasta alcanzar una solución (Aggarwal, 2018; Montesinos López et al., 2022, p. 407).

Función de activación: Deciden si una neurona artificial debe activarse o no. Su objetivo es limitar la salida de la neurona artificial dentro de un intervalo de valores razonables que fueron asumidas (Aggarwal, 2018; Montesinos López et al., 2022, p. 387).

Neurona artificial: Es la unidad de procesamiento más pequeña de una red neuronal artificial, que recibe señales de entrada y produce señales de salida, capaces de modelar relaciones de datos no lineales, identificar patrones, hacer predicciones, clasificaciones, entre

otros problemas complejos (Aggarwal, 2018; Montesinos López et al.,2022, p. 382).

Señales de entrada: Valores asumidos por las variables de una aplicación específica. Es decir, son las variables independientes de un modelo (Aggarwal, 2018; Montesinos López et al., 2022, p. 382).

Señales de salida: Valor final en relación de un determinado conjunto de señales de entrada. Es decir, es la variable dependiente del modelo (Aggarwal, 2018; Montesinos López et al., 2022, p. 382).

CAPÍTULO III

MARCO METODOLÓGICO

3.1. Localización de la investigación

Los datos dendrométricos requeridos para este estudio son provenientes de la Parcela de Corta 04, 06 y 07 de la Concesión Forestal Maderable N° 22-SAM/C-J-017-03 Aserradero Tarapoto S.A.C en el distrito de Pachiza, provincia de Mariscal Cáceres, Región San Martín, las mismas que se encuentran entre los 430 y 1000 metros sobre el nivel del mar. En estas parcelas se encontraron los tocones y al mismo tiempo donde se realizaron los inventarios tipo censos forestales, para el desarrollo de la investigación.

En la Tabla 1, Se aprecia la ubicación política de la Concesión y la Figura 1 se aprecia el mapa de ubicación de la concesión y de las parcelas de corta 04, 06 y 07 donde se realizó la recolección de datos.

Tabla 1


Ubicación política de la Concesión Forestal Maderable N° 22-SAM/C-J-017-03

| Región | Provincia | Distritos | Cuenca /Sub cuenca |
|---------------|------------------|----------------------|---------------------------|
| San Martín | Mariscal Cáceres | Pachiza | Huayabamba /Pachicilla |
| | Huallaga | Saposoa Piscoyacu | |

Nota. Resolución directoral ejecutiva N°1662020/GRSM/ARA/DEACRN—
Autoridad Regional Ambiental – San Martín

Figura 1

Mapa de ubicación de la Concesión Forestal Maderable N° 22-SAM/C-J-017-03



Nota. La figura muestra la ubicación geográfica con coordenadas UTM de las parcelas de corta de la Concesión donde se obtuvo los datos para la investigación.

3.1.1. Ubicación geográfica de la Concesión

La concesión forestal maderable N° 22-SAM/C-J-017-03 se ubica en las siguientes coordenadas (Tabla 2):

Tabla 2

Coordenadas UTM de la concesión forestal maderable N° 22-SAM/C-J-017-03

| Punto | Este (E) | Norte (N) | REFERENCIA |
|--------------|-----------------|------------------|-------------------|
| V1 | 290570 | 9226000 | Rio Pachicilla |
| V2 | 292800 | 9221000 | Rio Pachicilla |
| V3 | 274334 | 9221000 | |
| V4 | 274334 | 9226000 | |

Nota. Resolución Directoral Ejecutiva N°166 – 2020/GRSM/ARA/DEACRN – Autoridad Regional Ambiental – San Martín.

3.1.2. Ubicación y extensión de las Parcelas de Corta

La ubicación y extensión de las parcelas de corta se presenta en la siguiente tabla:

Tabla 3

Área y ubicación de las parcelas de Corta

| Ubicación | Número de parcela | Área |
|---------------------|--------------------------|------------------------------|
| Distrito de Pachiza | Parcela de Corta N° 04 | Área total (ha): 399.80 has. |
| | Parcela de Corta N° 06 | Área total (ha): 447.46 has. |
| | Parcela de Corta N° 07 | Área total (ha): 424.03 has. |

Nota. Resolución Directoral Ejecutiva N°166 – 2020/GRSM/ARA/DEACRN – Autoridad Regional Ambiental – San Martín.

3.1.3. Hidrografía y fisiografía

La red hidrográfica del Área de Concesión está conformada por el Río Pachicilla, no siendo navegable hasta la localidad de Bagazan. El río recorre planicies y terrenos colinosos, formando valles aluviales intramontanos. Además, presenta laderas con pendientes de 25% a 50%, ríos, quebradas y lluvias. Sin embargo, los valles formados en las partes media y baja de las principales fuentes de agua de la zona de estudio presentan altitudes que no sobrepasan a los 1000 metros sobre el nivel del mar (Resolución directoral ejecutiva N°166 – 2020/GRSM/ARA/DEACRN – Autoridad Regional Ambiental – San Martín).

3.2. Tipo y diseño de investigación

El tipo de investigación utilizado en este estudio fue correlativo. El diseño de este estudio es de tipo no experimental. El estudio es validado mediante indicadores estadísticos (Campos y Leite, 2017).

3.2.1. Unidad de análisis

La población y muestra estuvo representada por la base de datos de la concesión Forestal Maderable N° 22-SAM/C-J-017-03, conformado por 2936 datos mensurables del diámetro del tocón y volumen observado calculado, tanto del inventario y trozado. El análisis del estudio se realizó con la base de inventario al 100 % (Campos y Leite, 2017).

3.2.2. Fuentes, técnicas e instrumentos de recolección de datos

La investigación se apoyó en una fuente secundaria para obtener datos de registros de la concesión y la autoridad regional forestal. Para recopilar información adicional, se consultaron libros, revistas científicas, tesis y se buscó asesoramiento de un especialista en el área de investigación. Los datos son provenientes de la base de datos de la concesión Forestal Maderable N° 22-SAM/C-J-017-03.

La técnica utilizada fue la observación indirecta con presencia del investigador, además se utilizó la técnica de revisión de registros existentes.

Los instrumentos que se utilizaron fueron formatos de recolección de datos, los mismos que están establecidos por los softwares de procesamiento de datos para las correlaciones que se realizó.

3.2.3. Validación y prueba de confiabilidad

La fiabilidad de la investigación fue mediante el juicio de un experto en el tema.

3.2.4. Procedimiento de la investigación

3.2.4.1. Banco de datos.

La investigación fue desarrollada con la base de datos de 3 parcelas de corta forestal provenientes de la concesión forestal N.º 22-SAM/C-J-017-03, Pachiza Mariscal Cáceres - San Martín. El performance del estudio fue mediante la gráfica de correlación entre el volumen y el diámetro de tocón, siguiendo la tendencia potencial, se realizó la descripción estadística y análisis de frecuencias de errores (Campos & Leite, 2017).

Los datos climáticos fueron solicitados a la base de datos climáticos del SENAMHI.

3.2.4.2. Índices de competición.

En 1979, Glover y Holl propusieron tres índices independientes a la distancia (IID) para medir la competencia entre árboles: el índice de densidad puntual de diámetro (IID1), el índice de densidad puntual de altura (IID2) y el índice de densidad puntual de diámetro y altura (IID3). Estos índices se basan en la idea de que la competencia entre árboles se produce por la limitación de los recursos, como el espacio, el agua y la luz.

IID1 se calcula como la relación entre el diámetro al cuadrado del árbol i y la media aritmética de los diámetros al cuadrado de los árboles en la unidad de muestra. A menor valor del índice, mayor es la competencia sobre el árbol i .

IID2 se calcula como la relación entre la altura del árbol i y la media aritmética de las alturas de los árboles en la unidad de muestra. A menor valor del índice, mayor es la competencia sobre el árbol i .

IID3 se calcula como la relación entre el diámetro al cuadrado del árbol i y la media aritmética de los diámetros al cuadrado de los árboles en la unidad de muestra y como la relación entre la altura del árbol i y la media aritmética de las alturas de los árboles en la unidad de muestra. A menor valor del índice, mayor es la competencia sobre el árbol i .

Las ecuaciones de cada índice de competición independiente a la distancia aplicados en este estudio fueron las siguientes:

$$IID1 = \frac{DAP_i^2}{\overline{DAP^2}} \quad IID2 = \frac{H_i}{\overline{H}} \quad IID3 = \frac{DAP_i^2 H_i}{\overline{DAP^2} \overline{H}}$$

Donde:

DAP_i^2 = diámetro al cuadrado del árbol i .

$\overline{DAP^2}$ = Media aritmética de los diámetros al cuadrado de los árboles en la unidad de muestra.

H_i = altura del árbol i

\overline{H} = media aritmética de las alturas de los árboles en la unidad de muestra

3.2.4.3. Validación del rendimiento estadístico.


La validación del rendimiento estadístico del modelo se llevó a cabo mediante la utilización de una segunda base de datos externa, proveniente de la concesión forestal maderable N° 22-SAM/C-J-017-03, que representa un hito al ser la primera concesión de este tipo. Este proceso implicó el entrenamiento del modelo con los datos de la primera concesión, mientras que para su validación estadística se utilizaron los datos de esta segunda concesión (Figura 2).

La evaluación de los datos de validación estadística se realizó considerando una serie de indicadores clave, como la correlación (R) entre el volumen observado y estimado, la Raíz Cuadrada del Error Medio (RCEM %), el Bias (Bias %). Además, se interpretó el gráfico de distribución de porcentaje de error relativo (ER %) frente al ajuste. Estos criterios ofrecen una comprensión integral del desempeño y la precisión del modelo.

Para llevar a cabo este análisis, se empleó el software NeuroForest versión 4.0 desarrollado por Binoti en 2012, una herramienta reconocida por su eficacia en la evaluación y procesamiento de datos forestales. La utilización de este software permitió realizar un análisis exhaustivo y preciso que respalde la validez y fiabilidad de los resultados obtenidos en esta validación estadística (Binoti, 2012).

Figura 2

Implementación de la estrategia de validación para evaluar el desempeño estadístico del modelo desarrollado por la concesión 1



Nota. Se visualiza las dos Concesiones (C1 y C2 donde se realizó la obtención de la muestra, con su ubicación política a nivel distrital y provincial.

Las fórmulas de los indicadores estadísticos utilizados fueron:

$$R = \frac{n^{-1} \sum_{i=1}^n (Y_{pi} - \hat{Y}_m)(Y_i - \bar{Y})}{\sqrt{n^{-1} \sum_{i=1}^n (Y_{pi} - \hat{Y}_m)^2 n^{-1} \sum_{i=1}^n (Y_i - \bar{Y})^2}}; \quad Y_m = n^{-1} \sum_{i=1}^n Y_{pi} \quad RCEM\% = 100 \bar{Y}_i^{-1} \sqrt{n^{-1} \sum_{i=1}^n (Y_i - Y_i)^2}$$

$$ER\% = 100 \left(\frac{Y_i - \hat{Y}_i}{Y_i} \right) \quad Bias\% = 100 \bar{Y}_i^{-1} \sum_{i=1}^n \frac{(\hat{Y}_i - Y_i)}{n}$$

Donde n = Numero de observaciones, \hat{Y}_i = Volumen predictor, Y_i = Volumen observado

and \bar{Y} = Media del volumen observado

3.2.4.4. Arquitectura y algoritmos de la red neuronal artificial

Las predicciones fueron realizadas con la técnica de redes neuronales artificiales. Los datos fueron normalizados con la técnica de máximo y mínimo con la siguiente formula:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

En que:

X' = valor normalizado

X_{max} = mínimo valor de los datos

X_{min} = máximo valor de los datos

El tipo de arquitectura fue de una red neuronal simple de Multilayer Perceptron con 3 capas (1 Capa de entrada, 1 Capa oculta y 1 Capa de salida). La función de activación para la capa oculta y de salida fue sigmoideal. Su configuración consistió en 0.0001 de criterio de parada (error medio) y 3000 ciclos (Casas et al., 2022).

Se evaluaron 10 tipos de algoritmos:

- 1) Resilient propagation

- 2) Backpropagation
- 3) Quick propagation
- 4) Algoritmos genéticos
- 5) Neat
- 6) HyperNeat
- 7) RBF Neural Network
- 8) Support Vector Machine
- 9) Elman
- 10) Jordan

3.2.5. Aspectos éticos considerados

Cientificidad. Los procesos investigativos, se fundamentan en los aspectos metodológicos de la investigación científica, donde se puso en práctica el análisis e interpretación de los resultados mediante indicadores estadísticos de análisis de predicciones.

Veracidad. La presente investigación es inédita del autor, respetando los supuestos teóricos de los autores, debidamente referenciados. Se obtiene autorización para manipular y publicar la base de datos de la concesión forestal N° 22-SAM/C-J-017-03 y que los datos son únicamente utilizados con fines de investigación.

Compromiso institucional. Se considera importante el aporte de la universidad y regional para mejorar la información y conocimientos. El estudio es importante para la comunidad forestal, empresas y concesionarias forestales para mejorar y tomar decisiones en temas de manejo forestal y ambiental en áreas de extracción maderable.

Respeto a la propiedad intelectual. Se redactó tomando en cuenta las fuentes citadas de otros autores e investigadores, para respetar la propiedad intelectual; además el documento final fue escrutado por el software antiplagio Turnitin, para garantizar este principio ético.

3.2.6. Presentación de información

Para la redacción, consolidación y presentación del informe final, los datos se procesaron en hoja de cálculo (Excel) para elaborar tablas y figuras; y hoja de texto (Word) para realizar la redacción del informe de investigación, realizar los análisis e interpretación de resultados. Una vez obtenido los resultados y su respectivo análisis, se procedió a redactar el informe final de tesis, según lo establecido en el Protocolo de la Facultad de Ciencias Agrarias; se utilizó la norma de redacción APA 7ª Edición.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. Análisis de los datos

4.1.1. Análisis del Inventario Forestal

Tabla 4

Características dendrométricas promedio de especies arbórea encontradas en la base de datos de la concesión 1

| Nº | Nombre Científico | Nombre común | Nº individuos | Promedio DAP (cm) | Promedio Altura Comercial (m) | Promedio Volumen (m ³) |
|----|---|---------------|---------------|-------------------|-------------------------------|------------------------------------|
| 1 | <i>Calophyllum brasiliense</i> Cambess | Alfaro | 110 | 76,23 | 16,92 | 6,37 |
| 2 | <i>Caryocar amygdaliforme</i> Ruiz & Pav. Ex G. Don | Almedro | 8 | 74 | 18,63 | 5,67 |
| 3 | <i>Apuleira leiocarpa</i> (Vogel) J.F. Macbr. | Ana caspi | 10 | 95,9 | 19,70 | 9,83 |
| 4 | <i>Trattinnickia aspera</i> (Stanl.) Swart | Caraña | 69 | 81,1 | 15,97 | 6,05 |
| 5 | <i>Hura crepitans</i> L. | Catahua | 58 | 111,67 | 18,6 | 13,51 |
| 6 | <i>Cedrela fissilis</i> Vell. | Cedro de agua | 51 | 103,98 | 18,61 | 20,90 |
| 7 | <i>Cedrela montana</i> Moritz ex Turcz. | Cedro virgen | 91 | 96,15 | 19,79 | 24,79 |
| 8 | <i>Protium nodulosum</i> Swart | Copal | 24 | 93,17 | 17,54 | 8,46 |
| 9 | <i>Virola calophylla</i> (Spruce) Warb. | Cumala | 30 | 66,10 | 17,13 | 8,20 |
| 10 | <i>Parkia nitida</i> Miq. | Goma pashaco | 5 | 66,40 | 18,60 | 4,27 |
| 11 | <i>Hierronyma asperifolia</i> ax & K. Hoffm. | Manzano | 4 | 70,00 | 17,00 | 4,47 |
| 12 | <i>Aniba panurensis</i> (Meisn.) Mez | Moena | 463 | 78,39 | 15,05 | 8,13 |
| 13 | <i>Schizolobium amazonicum</i> Huber ex Ducke | Pashaco | 4 | 68,75 | 16,50 | 4,16 |
| 14 | <i>Pachira insignis</i> (Sw.) Sw. Ex Savigny | Punga | 127 | 85,30 | 17,35 | 8,95 |
| 15 | <i>Ficus pertusa</i> L. f. | Renaco | 5 | 79,40 | 15,8 | 5,35 |
| 16 | <i>Miconia poeppigii</i> Triana | Rifari | 127 | 96,95 | 14,96 | 7,43 |
| 17 | <i>Cedrelinga cateniformis</i> (Ducke) (Ducke) | Tornillo | 1666 | 110,91 | 21,02 | 16,16 |
| 18 | <i>Poulsenia armata</i> (Miq.) Standl. | Yanchama | 84 | 86,46 | 16,52 | 6,63 |

Nota. Datos dendrométricos promedio de los árboles por especie. Fuente: Base de datos de la Concesión 1, (Anexo 3).

En la tabla 4, detalla diversas especies de árboles de la base de datos de la concesión 1, ofreciendo datos sobre la cantidad de árboles por especie junto con sus características promedio. La cantidad de especies varía notablemente, desde apenas 4 árboles (manzano) hasta una presencia considerable de 1 666 árboles (tornillo) de especies. En cuanto al diámetro promedio a la altura del pecho (DAP), este oscila entre 66,10 cm y 111,67 cm, con

una media aproximada de 89,42 cm.

En lo referente a la altura comercial, se observa una diversidad que va desde los 14,96 metros hasta los 21,02 metros, con un promedio cercano a los 17,79 metros. Por último, el volumen promedio, muestra una amplia variación, desde los 4,16 m³ hasta los 24,79 m³, con una media aproximada de 10,92 m³.

Tabla 5

Características dendrométricas promedio de especies arbórea encontradas en la base de datos de la concesión 2.

| Nº | Nombre Científico | Nombre común | Nº individuos | Promedio DAP (cm) | Promedio Altura Comercial (m) | Promedio Volumen (m ³) |
|----|---|--------------|---------------|-------------------|-------------------------------|------------------------------------|
| 1 | <i>Protium nodulosum</i> Swart | Copal | 38 | 72,45 | 14,42 | 4,06 |
| 2 | <i>Ormosia Coccinea</i> | Huayruro | 1 | 82 | 18,00 | 6,18 |
| 3 | <i>Brosimum alicastrum</i> | Manchinga | 18 | 85,33 | 17,00 | 6,85 |
| 4 | <i>Aniba panurensis</i> (Meisn.) Mez | Moena | 65 | 73,08 | 15,06 | 4,53 |
| 5 | <i>Crypturellus undulatus</i> | Panguana | 41 | 68,46 | 14,63 | 3,66 |
| 6 | <i>Miconia poeppigii</i> Triana | Rifari | 84 | 68,76 | 13,79 | 3,44 |
| 7 | <i>Cedrelinga cateniformis</i> (Ducke) (Ducke) | Tornillo | 530 | 83,78 | 16,98 | 6,63 |
| 8 | <i>Terminalia Oblonga</i> | Yacushapana | 90 | 77,38 | 14,39 | 4,67 |

Nota. Datos dendrométricos promedio de los árboles por especie. Fuente: Base de datos de la Concesión 2, (Anexo 3).

La tabla 5, ofrece información detallada sobre diversas especies arbóreas de la base de datos de la concesión 2. La cantidad de árboles por especie varía significativamente, desde solo uno (huayruro) hasta 530 árboles (tornillo) por especie. En cuanto al diámetro a la altura del pecho (DAP) promedio, fluctúa entre 68,46 cm y 85,33 cm, presentando una media de aproximadamente 76,08 cm. Respecto a la altura comercial promedio, esta oscila entre 13,79 metros y 18,00 metros, con un promedio cercano a los 15,81 metros. En términos de volumen promedio, se observan valores entre 3,44 m³ y 6,85 m³, con una media de alrededor de 5,02 m³.

4.1.2. Análisis de Consistencia de Datos del Trozado Forestal

El trozado forestal se realizó solo para la especie de estudio que fue el tornillo.

Tabla 6

Análisis estadístico del diámetro del tocón y volumen de datos recopilados en la base de datos de la concesión 1

| Descripción estadística | Diámetro del tocón (m) | Volumen (m ³) |
|-------------------------------|------------------------|---------------------------|
| Media | 1,084 | 13,759 |
| Error estándar | 0,009 | 0,254 |
| Mediana | 1,060 | 12,480 |
| Desviación estándar | 0,241 | 6,804 |
| Varianza de la muestra | 0,058 | 46,293 |
| Kurtosis | 0,220 | 0,638 |
| Asimetría | 0,484 | 0,861 |
| Rango | 1,580 | 38,965 |
| Mínimo | 0,620 | 1,589 |
| Máximo | 2,060 | 40,555 |
| Suma | 7,770 | 98,650 |
| Cantidad | 7,170 | 71,700 |
| Coefficiente de variación (%) | 22,250 | 49,410 |
| Nivel de Confianza (95.0 %) | 0,018 | 0,499 |

Nota. Datos de estadísticos obtenidos del análisis de la base de datos de la concesión 1, (Anexo 3).

La tabla 6, proporciona un análisis estadístico detallado del diámetro del tocón y el volumen recopilado de la concesión 1. La media del diámetro del tocón es de 1 084 metros. La mediana, que es 1 060 metros, sugiere que la mitad de los datos registrados están por encima y la otra mitad por debajo de este valor, mostrando una distribución cercana entre los valores extremos. La desviación estándar de 0,241 metros representa la dispersión de los datos alrededor de la media; valores más altos indicarían una mayor variabilidad. La curtosis de 0,220, al estar cerca de cero, sugiere una distribución aproximadamente normal alrededor de la media. La asimetría de 0,484 muestra cierta asimetría positiva, indicando una ligera cola hacia la derecha en la distribución. El rango del diámetro del tocón es de 1580 metros, desde el valor mínimo de 0,480 metros hasta el máximo de 2 060 metros, lo que refleja la amplitud total de los datos recopilados. En cuanto al volumen, la media es de 13 759 metros cúbicos, mientras que la mediana es de 12,480 metros cúbicos, mostrando una tendencia similar a la del diámetro del tocón. La desviación estándar de 6,804 metros cúbicos indica la dispersión de los valores alrededor de la media en términos de volumen. El rango del volumen es más amplio, con un máximo de 40 555 metros cúbicos y un mínimo de 1 589 metros cúbicos.

Tabla 7

Análisis estadístico del diámetro del tocón y volumen de datos recopilados en la base de datos de la concesión 2.

| Descripción estadística | Diámetro del tocón (m) | Volumen (m ³) |
|-------------------------------|------------------------|---------------------------|
| Media | 0,949 | 9,869 |
| Error estándar | 0,015 | 0,393 |
| Mediana | 0,910 | 8,291 |
| Desviación estándar | 0,220 | 5,764 |
| Varianza de la muestra | 0,048 | 33,228 |
| Kurtosis | 0,767 | 3,584 |
| Asimetría | 0,920 | 1,727 |
| Rango | 1,080 | 30,756 |
| Mínimo | 0,620 | 2,906 |
| Máximo | 1,700 | 33,662 |
| Suma | 204,06 | 2121,90 |
| Cantidad | 215 | 215 |
| Coefficiente de variación (%) | 23,19 | 58,32 |
| Nivel de Confianza (95.0 %) | 0,030 | 0,775 |

Nota. Datos de estadísticos obtenidos del análisis de la base de datos de la concesión 2, (Anexo 3).

En la tabla 7, ofrece una descripción detallada de dos variables: el diámetro del tocón y el volumen correspondiente de la base de datos de la concesión 2, presentando una serie de estadísticas descriptivas. La media del diámetro del tocón se ubica en 0,949 metros, mientras que, para el volumen, la media es de 9,869 metros cúbicos. El error estándar, que mide la precisión de la media estimada, es de 0,015 metros para el diámetro del tocón y 0,393 metros cúbicos para el volumen, mostrando la variabilidad en torno a la media. La mediana, situada en 0,910 metros para el diámetro y 8 291 metros cúbicos para el volumen, señala el valor central de los datos y sugiere una distribución cercana entre los valores extremos. La desviación estándar, de 0,220 metros para el diámetro y 5 764 metros cúbicos para el volumen, indica la dispersión de los datos alrededor de la media, donde valores mayores reflejarían mayor variabilidad. La curtosis, con valores de 0,767 para el diámetro y 3 584 para el volumen, sugiere cierta concentración de datos alrededor de la media y la presencia de colas más pesadas que una distribución normal. La asimetría, con valores de 0.920 para el diámetro y 1 727 para el volumen, indica una distribución asimétrica positiva, con la mayoría de los datos en el lado izquierdo de la media. El rango, que muestra la diferencia entre el valor máximo y mínimo, es de 1,080 metros para el diámetro y 30 756 metros cúbicos para el volumen.

Al comparar los dos conjuntos de datos (base de datos de la concesión 1 y 2), se evidencia una diferencia cuantitativa significativa en las medidas estadísticas. En la concesión 2, tanto el diámetro del tocón (0,949 m) como el volumen (9 869 m³) muestran valores más bajos en medidas centrales como la media y la mediana en comparación con la base de datos de la concesión 1 (diámetro: 1 084 m, volumen: 13 759 m³). Además, las desviaciones estándar en concesión 2 para el diámetro (0,220 m) y el volumen (5 764 m³) también son inferiores respecto al cuadro original (diámetro: 0,241 m, volumen: 6 804 m³), indicando una menor dispersión de los datos alrededor de la media en el nuevo conjunto. Sin embargo, la curtosis y la asimetría en la base de datos de la concesión 2 son mayores en ambas variables, señalando una mayor concentración alrededor de la media y una distribución más asimétrica hacia la derecha en comparación con la base de datos de la concesión 1. Estos resultados cuantitativos reflejan una diferencia marcada en la tendencia central y la distribución de los datos entre ambos conjuntos.

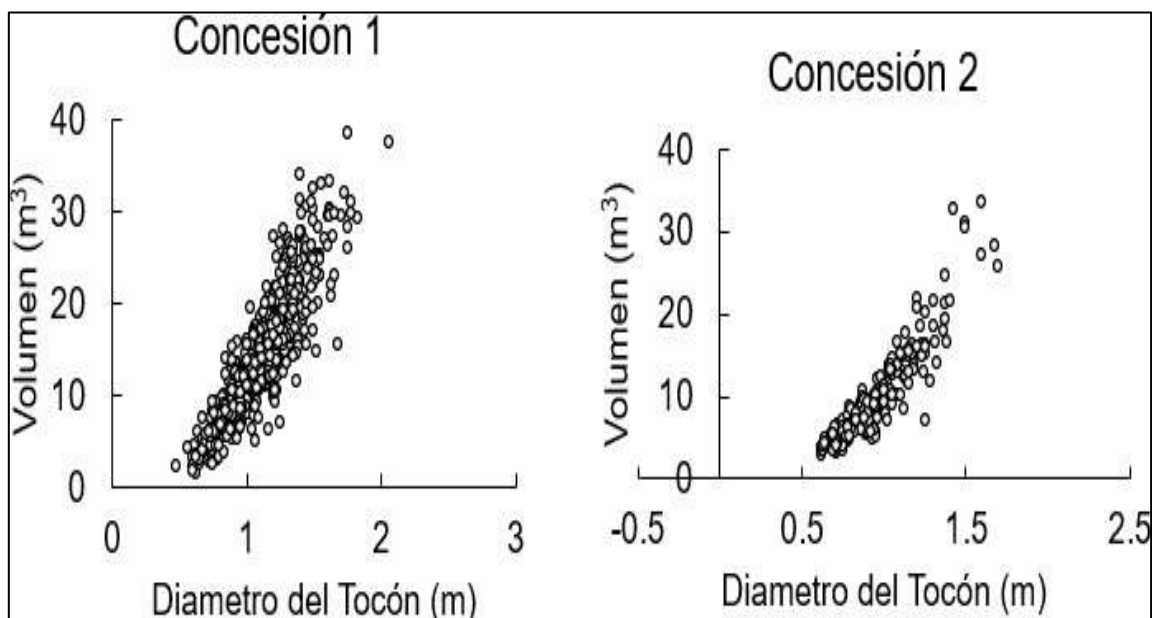
Según la prueba estadística de t de Student para las muestras independientes, donde se comparó las medias de las dos muestras (las medidas de diámetro del tocón y volumen de la base de datos de las concesiones 1 y 2) Con la finalidad determinar si existen diferencias significativas entre ellos. La prueba t de Student evaluó si las diferencias observadas entre los conjuntos de datos son atribuibles al azar o si realmente representan una discrepancia significativa entre las poblaciones de las cuales se extrajeron los datos.

Los valores p obtenidos para el diámetro del tocón y el volumen son menores a 0,05, lo que suele interpretarse como una fuerte evidencia en contra de la hipótesis nula. En este contexto, la hipótesis nula fue que no hay diferencia significativa entre las medias de los dos conjuntos de datos. Por lo tanto, con valores $p < 0,05$, se puede concluir que hay una diferencia estadísticamente significativa entre las medias del diámetro del tocón y el volumen entre los dos conjuntos de datos. En otras palabras, hay suficiente evidencia para afirmar que las muestras provienen de poblaciones diferentes en términos de estas variables.

Se generaron figuras de dispersión entre el volumen y el diámetro (Figura 3), donde se teorizaba que esta relación seguiría una tendencia potencial (Campos y Leite, 2017), en que efectivamente ambas relaciones mostraron una tendencia potencial, lo que permitió validar los modelos empleados para datos provenientes de dos áreas diferentes con una tendencia similar, pero con diferencias estadísticas significativas.

Figura 3

Dispersión de la relación del diámetro del tocón y el volumen provenientes de la base de datos de la concesión 1 y concesión 2



Nota. Gráfico de dispersión de puntos, según valores obtenidos del procesamiento de datos.

4.2. Análisis de índice de competición

En la tabla 8, se indica los valores promedio de tres índices de competencia propuestos por Glover e Holl (1979) para 13 especies de árboles para la concesión 1. La interpretación de los índices es que, a menor valor del índice, mayor es la competencia sobre el árbol en cuestión. Esto implica que valores más bajos en estos índices indican una mayor presión competitiva sobre el árbol individual dentro de su entorno, lo que puede tener implicaciones significativas en términos de crecimiento y recursos disponibles para ese árbol específico dentro del contexto de la competencia intraespecífica.

Tabla 8

Análisis de índices de competición entre especies arbóreas en la base de datos de la concesión 1.


| Nº | Nombre Científico | Nombre común | Promedio IID1 | Promedio IID2 | Promedio IID3 |
|----|---|---------------|---------------|---------------|---------------|
| 1 | <i>Calophyllum brasiliense</i> Cambess | Alfaro | 0,32612 | 0,88947 | 0,28538 |
| 2 | <i>Caryocar amygdaliforme</i> Ruiz & Pav. Ex G. Don | Almedro | 0,54777 | 1,008 | 0,56085 |
| 3 | <i>Apuleira leiocarpa</i> (Vogel) J.F. Macbr. | Ana caspi | 0,86249 | 1,03591 | 0,8929 |
| 4 | <i>Trattinnickia aspera</i> (Stanl.) Swart | Caraña | 0,78178 | 0,84948 | 0,71819 |
| 5 | <i>Hura crepitans</i> L. | Catahua | 2,63229 | 1,00552 | 2,77105 |
| 6 | <i>Cedrela fissilis</i> Vell. | Cedro de agua | 1,61461 | 0,9951 | 1,64572 |
| 7 | <i>Cedrela montana</i> Moritz ex Turcz. | Cedro virgen | 1,43515 | 1,07141 | 1,63593 |
| 8 | <i>Protium nodulosum</i> Swart | Copal | 1,14738 | 0,92951 | 1,04676 |
| 9 | <i>Virola calophylla</i> (Spruce) Warb. | Cumala | 0,22203 | 0,91596 | 0,21074 |
| 10 | <i>Parkia nitida</i> Miq. | Goma pashaco | 0,24227 | 1,00665 | 0,25139 |
| 11 | <i>Hierronyma asperifolia</i> ax & K. Hoffm. | Manzano | 0,34128 | 0,92006 | 0,32277 |
| 12 | <i>Aniba panurensis</i> (Meisn.) Mez | Moena | 0,40597 | 0,79011 | 0,3287 |
| 13 | <i>Schizolobium amazonicum</i> Huber ex Ducke | Pashaco | 0,29139 | 0,893 | 0,27706 |
| 14 | <i>Pachira insignis</i> (Sw.) Sw. Ex Savigny | Punga | 0,50648 | 0,90958 | 0,47234 |
| 15 | <i>Ficus pertusa</i> L. f. | Renaco | 0,63621 | 0,85511 | 0,56156 |
| 16 | <i>Miconia poeppigii</i> Triana | Rifari | 0,82829 | 0,77933 | 0,63066 |
| 17 | <i>Cedrelinga cateniformis</i> (Ducke) (Ducke) | Tornillo | 2,02844 | 1,1001 | 2,38447 |
| 18 | <i>Poulsenia armata</i> (Miq.) Standl. | Yanchama | 0,87064 | 0,89428 | 0,78395 |

Nota. IID,= índices de competición promedio calculado. Fuente: elaborado con los datos de la concesión 1, (Anexo 4).

En la tabla 8 se observa los valores de los índices IID1, IID2 e IID3 para cada especie (Tabla 8), se evidencia que aquellas especies con valores más bajos en estos índices experimentan una mayor competencia entre sus árboles individuales dentro del ecosistema en comparación con aquellas especies que presentan valores más altos en estos índices. Por ejemplo, especies como cumala, goma pashaco y moena tienen valores relativamente bajos en los tres índices, lo que sugiere una mayor competencia intraespecífica entre sus árboles. En contraste, especies como catahua y tornillo presentan valores más altos en los índices, indicando una menor competencia entre sus árboles individuales en el mismo entorno. Es importante tener en cuenta que estos resultados se basan en promedios, por lo que es posible que haya individuos de una especie que experimenten mayor o menor competencia que el promedio de la especie, que a mayor detalle individual se puede observar en el anexo 3.

Figura 4

Mapa de dispersión de las especies en el entorno de la concesión 1



Nota. Se muestran la dispersión de los árboles de tornillo en la parcela de corta, identificándose de color rojo.

Tabla 9

Análisis de índices de competencia entre especies arbóreas en la base de datos de la Concesión 2


| Nº | Nombre científico | Nombre común | Promedio IID1 | Promedio IID2 | Promedio IID3 |
|----|--|--------------|---------------|---------------|---------------|
| 1 | <i>Protium nodulosum</i> Swart | Copal | 0,75671 | 0,90436 | 0,72583 |
| 2 | <i>Ormosia Coccinea</i> | Huayruro | 1,09900 | 1,1857 | 1,30309 |
| 3 | <i>Brosimum alicastrum</i> | Manchinga | 1,48033 | 1,05661 | 1,68486 |
| 4 | <i>Aniba panurensis</i> (Meisn.) Mez | Moena | 0,84883 | 0,93813 | 0,89817 |
| 5 | <i>Crypturellus undulatus</i> | Panguana | 0,57883 | 0,91913 | 0,5595 |
| 6 | <i>Miconia poeppigii</i> Triana | Rifari | 0,61099 | 0,88657 | 0,55118 |
| 7 | <i>Cedrelinga cateniformis</i> (Ducke) (Ducke) | Tornillo | 1,49087 | 1,05278 | 1,68317 |
| 8 | <i>Terminalia Oblonga</i> | Yacushapana | 1,01951 | 0,90357 | 0,96297 |

Nota: IID,= índices de competición promedio calculado. Fuente: elaborado utilizando la base de datos de la concesión 2, (Anexo 4).

La tabla 9, indica los valores promedio de tres índices de competencia propuestos por Glover e Holl (1979) para 13 especies de árboles para la tabla 9. Al analizar los valores de los índices para cada especie en esta nueva tabla, se observa que especies como copal, moena y yacushapana presentan valores relativamente bajos en los tres índices, lo que sugiere una alta competencia entre los árboles de la misma especie en un área específica. Por otro lado, especies como huayruro, manchinga y tornillo exhiben valores más altos en los índices, indicando una menor competencia intraespecífica en comparación con las anteriores. Figura 5 muestra el mapa de dispersión en el entorno de la concesión 2.

Figura 5

Mapa de dispersión de las especies en el entorno de la Concesión 2



Nota: Se muestran la dispersión de los árboles de tornillo en la parcela de corta, identificándose de color rojo

En comparación entre ambas concesiones que analizamos, se observa que algunas especies mantienen un comportamiento similar en términos de competencia. Por ejemplo, Moena muestra valores bajos en ambas concesiones, lo que sugiere una alta competencia en ambas muestras. Sin embargo, hay diferencias entre especies como copal y tornillo. En la Concesión 1, tornillo tenía un valor alto, indicando una menor competencia, mientras que en la concesión 2, tornillo muestra valores más bajos, sugiriendo una mayor competencia. Esto puede sugerir variabilidad en la competencia intraespecífica entre diferentes muestras o contextos ecológicos, esta comparativa de datos proporciona una visión de la competencia intraespecífica entre diferentes especies arbóreas de dos sitios. En el anexo 3, se aprecian a mayor de talle los índices de competición para cada árbol.

4.3. Descripción de los datos climáticos

Los datos climáticos son provenientes de la estación climática más cercana al área de estudio y las variables pertenecen al año 2022, tanto para la concesión 1 y 2. Las variables proporcionadas fueron la precipitación total, las temperaturas máximas y mínimas promedio, la temperatura promedio mensual, la humedad relativa promedio y la evaporación total mensual.

Tabla 10

Registro mensual y anual de las condiciones climáticas en el área de la concesión 1.

| Meses | P.T. M (mm) | T. Max. P.M (C) | T. Min.P.M (C) | T.P.M (C) | H.R.P.M (H) | E.T.M (mm) |
|-----------|-------------|-----------------|----------------|-----------|-------------|------------|
| Enero | 104 | 34 | 21,8 | 27,5 | 83 | 116,4 |
| Febrero | 190,5 | 31,6 | 21,6 | 26,1 | 88 | 86,9 |
| Marzo | 247,9 | 31,2 | 21,2 | 25,8 | 89 | 86,3 |
| Abril | 98,8 | 32 | 21,4 | 26 | 88 | 90,6 |
| Mayo | 126,3 | 31,6 | 21 | 26,7 | 88 | 88,9 |
| Junio | 110 | 31,5 | 20 | 25 | 88 | 87,6 |
| Julio | 41,9 | 33,2 | 20,5 | 25,9 | 87 | 68,6 |
| Agosto | S/D | S/D | S/D | S/D | S/D | S/D |
| Setiembre | S/D | S/D | S/D | S/D | S/D | S/D |
| Octubre | S/D | S/D | S/D | S/D | S/D | S/D |
| Noviembre | 113,2 | 33,3 | 21,9 | 26,9 | S/D | 196,3 |
| Diciembre | 46,1 | 34 | 21,2 | 26,7 | S/D | 46,7 |
| Anual | 1078,7 | 34 | 20 | 26,29 | 87,29 | 868,30 |

Nota: P.T.M = Precipitación Total Mensual, T.Max.P.M = Temperatura Máxima Promedio Mensual, T.Min.P.M = Temperatura mínima Promedio Mensual, T.P.M = Temperatura Promedio Mensual, H.R.P.M = Humedad Relativa Promedio Mensual, E.T. M = Evaporación Total Mensual. Fuente: Servicio Nacional de Meteorología e Hidrología del Perú, SENAMHI, Estación Saposoa (2023).

La tabla 10, presenta los datos climáticos pertenecientes al área de la concesión 1. La precipitación mensual muestra variaciones a lo largo del año, siendo marzo el mes con la precipitación más alta (247,9 mm). Las temperaturas máximas promedio varían entre 31,2 °C en marzo y 34 °C en enero y diciembre, mientras que las temperaturas mínimas promedio oscilan entre 20 °C en agosto y 21,9 °C en noviembre. La temperatura promedio mensual se encuentra alrededor de los 26,29 °C. La humedad relativa promedio mantiene una cifra constante alrededor del 87 %, con variaciones menores a lo largo del año 2023. En cuanto a la evaporación mensual, también hay fluctuaciones significativas, con meses como enero y noviembre registrando valores altos y otros meses mostrando cifras más bajas. También se encuentran datos registrados (S/D), indicando la falta de información disponible para estos meses o la ausencia de mediciones en ese período específico.

Tabla 11

Registro mensual y anual de las condiciones climáticas en el área de la concesión 2.

| Meses | P.T. M(mm) | T. Max.P.M (C) | T. Min.P.M(C) | T.P.M (C) | H.R.P.M(H) | E.T.M (mm) |
|-----------|------------|----------------|---------------|-----------|------------|------------|
| Enero | 91.4 | 33.1 | 20.4 | 27 | 79 | 153.9 |
| Febrero | 90.9 | 31.2 | 19.9 | 26.2 | 81 | 10.8 |
| Marzo | 115.6 | 31.8 | 19.9 | 26.5 | 80 | 126.4 |
| Abril | 124.9 | 31.9 | 19.8 | 26.3 | 80 | 121.2 |
| Mayo | 180.3 | 32.3 | 19.7 | 26.5 | 80 | 132.8 |
| Junio | 37.8 | 33.3 | 19.2 | 27 | 78 | 148.2 |
| Julio | 31.4 | 34.3 | 20 | 27.4 | 79 | 171.6 |
| Agosto | 115.1 | 34 | 19.7 | 27.1 | 79 | 165.5 |
| Setiembre | 35.9 | 34.6 | 20.4 | 27.9 | 79 | 177.6 |
| Octubre | 79.4 | 33.3 | 20.4 | 27.2 | 79 | 164.1 |
| Noviembre | 70.4 | 33.1 | 20.1 | 26.7 | 81 | 147.8 |
| Diciembre | 60.8 | 34.8 | 20.5 | 27.2 | 80 | 187.3 |
| Anual | 1033.9 | 34.8 | 19.2 | 26.91 | 79.58 | 1707.2 |

Nota: P.T.M = Precipitación Total Mensual, T.Max.P.M = Temperatura Máxima Promedio Mensual, T.Min.P.M = Temperatura mínima Promedio Mensual, T.P.M = Temperatura Promedio Mensual, H.R.P.M = Humedad Relativa Promedio Mensual, E.T. M = Evaporación Total Mensual. Fuente: Base de datos del Servicio Nacional de Meteorología e Hidrología del Perú, Senamhi, Estación Tingo de Ponanza 2023.

La tabla 11, presenta los datos climáticos pertenecientes al área de la concesión 2. En términos de la precipitación, se observa una variabilidad a lo largo del año, siendo mayo el mes con la precipitación más alta (180,3 mm) y junio y julio los meses con las cifras más bajas. Las temperaturas muestran una oscilación en las máximas y mínimas promedio, con

valores más altos en meses como agosto y diciembre, y valores más bajos en febrero y marzo. La temperatura promedio mensual se mantiene alrededor de los 26,91 °C, con variaciones a lo largo del año. La humedad relativa mensual se mantiene bastante constante alrededor del 79-81 %, con variaciones menores a lo largo de los meses. La evaporación mensual varía considerablemente, mostrando altos niveles en meses como agosto y diciembre, y valores más bajos en meses como febrero y marzo.

Comparativamente con el sitio de la concesión 1 y 2, se observan algunas diferencias en los patrones climáticos mensuales. La precipitación anual es similar en ambos sitios, pero las fluctuaciones mensuales varían en cuanto a la distribución de la lluvia y la evaporación a lo largo del año.

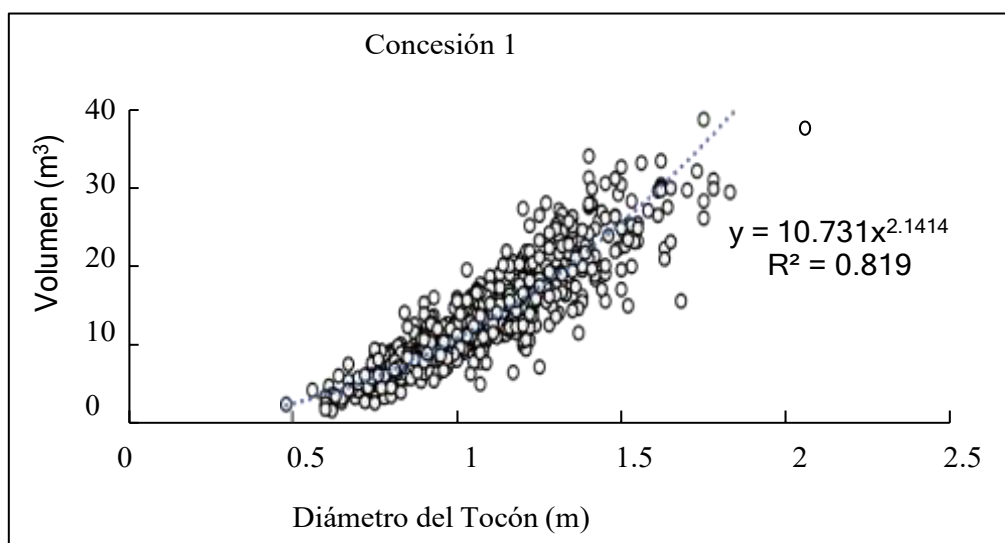
4.4. Análisis de Modelamiento

4.4.1. Análisis del Modelo Potencial

En esta etapa de modelamiento se utilizó la base de datos de la concesión 1 para ajustar los parámetros de la ecuación potencial $y = \beta_0 x^{\beta_1}$, mientras la base de datos de la concesión 2 fue utilizado para la validación de los datos predictivos. Cuando el modelo se aplica a la base de datos de la Concesión 1, los valores establecidos se denominan estimaciones. Cuando el modelo se aplica a la base de datos de la Concesión 2, los valores establecidos se denominan predicciones.

Figura 6

Relación entre el diámetro del tocón y el volumen con su línea de tendencia potencial de la base de datos de la concesión 1



Nota. Gráfico de dispersión de puntos, según valores obtenidos del procesamiento de datos.

En la figura 6, se muestra la relación entre el diámetro del tocón y el volumen de los árboles de la base de datos de la concesión 1. Al ajustar el modelo potencial se obtuvo la ecuación $y = 10,731x2,1414$, siendo y el volumen (m^3) y x el diámetro del tocón (m). Así mismo muestra la línea de tendencia potencial con su respectiva ecuación con un coeficiente de correlación (R^2) de 0,7942.

Tabla 12

Comparación de los indicadores estadísticos de la estimación y la predicción del modelo de regresión potencial

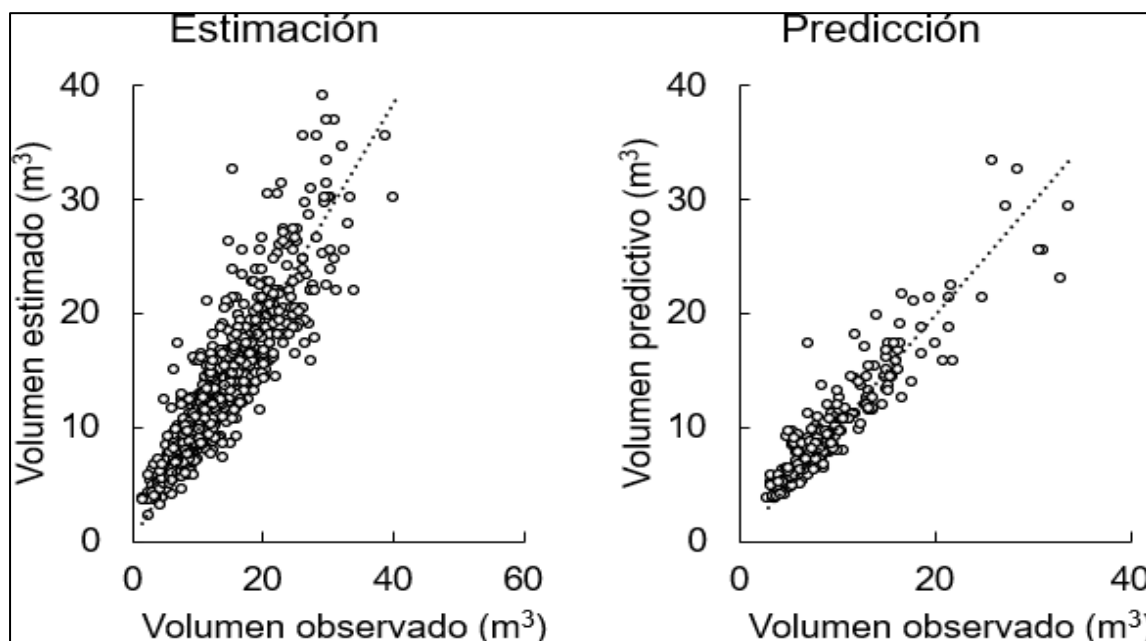
| Indicador | R^2 | R | RECM (%) | BIAS |
|------------|--------|--------|----------|---------|
| Estimación | 0,7942 | 0,8912 | 22,7684 | -0,2290 |
| Predicción | 0,8589 | 0,9268 | 22,1961 | 0,3566 |

Nota. Validación estadística de las estimaciones y predicciones con indicadores de ajuste.

En la tabla 12, se muestra los resultados de los indicadores estadísticos para ambas situaciones. El coeficiente de determinación (R^2) que indica la proporción de la varianza en la variable dependiente que es estimado o predecible a partir de la variable independiente. En este caso, la estimación tiene un R^2 de 0,7942, mientras que la predicción tiene un R^2 de 0,8589, lo que indica que el modelo tiene un mejor ajuste para la predicción que para la estimación. El coeficiente de correlación (R) entre las variables dependiente e independiente. Mientras más cerca esté de 1, mayor es la relación lineal entre los valores observados y estimados o predichos. Para la estimación es 0,8912 y para la predicción es 0,9268, lo que indica una relación más fuerte entre las variables para la predicción. El error cuadrático medio relativo (RECM %), que indica la precisión del modelo. En ambos casos (estimación y predicción), el valor es similar, alrededor del 22-23 %, lo que sugiere una consistencia en el error relativo entre ambas situaciones. El sesgo o BIAS, mide la tendencia del modelo a subestimar o sobreestimar los valores reales. Para la estimación, el BIAS es -0,2290, indicando un sesgo negativo, y para la predicción es 0,3566, mostrando un sesgo positivo. El sesgo es positivo para las predicciones lo que significa que el modelo tiende a sobreestimar los valores reales.

Figura 7

Correlación entre el volumen observado y estimado, base de datos de la concesión 1 y 2



Nota. Gráfico de dispersión de puntos, según valores obtenidos del procesamiento de datos comparando la estimación y la predicción de volúmenes de los árboles.


En la Figura 7, se representan dos partes: primero que muestra la correlación entre el volumen observado y estimado utilizando la base de datos de la concesión 1, y otro que grafica la correlación entre el volumen predicho y observado usando la base de datos de la concesión 2. Estas figuras nos ayudaron a interpretar el indicador de correlación mostrado en la Tabla 9, el cual revela que la correlación en la predicción es mayor que en la estimación. No obstante, al observar la Figura 2, se evidencia claramente que la base de datos empleada para la predicción del modelo cuenta con menos datos que la utilizada en la estimación. Esta disparidad en los tamaños de muestra puede influir significativamente en los resultados de los indicadores estadísticos. Este escenario es recurrente al analizar datos forestales, especialmente cuando el modelo se aplica en un área diferente con una fuente de datos distinta, lo que puede dificultar la toma de decisiones para un modelador forestal. A pesar de que el error cuadrático medio relativo es similar en ambos casos, es evidente que tanto el coeficiente de correlación como la correlación en sí misma pueden mostrar tendencias sesgadas al analizar datos predictivos en el contexto de la ingeniería forestal.

Se ha generado la distribución de las clases de error para los valores estimados y predictivos a partir del modelo potencial, presentándose en la Figura 8. Esta distribución

permite evaluar la precisión de las predicciones. Idealmente, la mayor cantidad de datos estimados o predichos debería ubicarse en la clase de error de 0 %. En las estimaciones, el 10 % de los datos se clasifican en el error de 0 %, mientras que, en las predicciones, este porcentaje se reduce al 7 %. En las estimaciones, se observa una concentración significativa de datos en la clase de error de -5 %, alcanzando un 11 %, mientras que, en las predicciones, la mayor concentración de datos se presenta en la clase de error de 5 %, con un 14 %. Estos resultados ponen de manifiesto la utilidad del indicador de sesgo (bias), ya que evidencia un sesgo positivo en las predicciones, indicando que el modelo tiende a sobreestimar los valores reales. Asimismo, se destaca la limitación del uso del coeficiente de correlación para la evaluación de datos predictivos en este contexto específico.

Figura 8

Distribución de las clases de error para los valores estimados y predictivos del modelo potencial



Nota. Se visualiza la distribución de los residuos de la estimación y predicción, teniendo una distribución más normalizada el caso de la estimación.

4.4.2. Análisis de las Redes Neuronales Artificiales

En esta investigación, buscamos mejorar las predicciones generadas por el modelo de

regresión de potencial, específicamente en la relación entre el diámetro del tocón y el volumen de los árboles. Para lograrlo, implementamos la técnica de redes neuronales artificiales. Esta metodología nos brindó la oportunidad de integrar un conjunto más amplio de variables relacionadas con las características ecológicas presentes en los ecosistemas forestales. Entre estas variables adicionales se incluyeron aspectos climáticos y diversos índices de competencia.

Para garantizar la comparabilidad de los resultados, se utilizó la base de datos de la concesión 1 que fue utilizado al ajustar el modelo potencial, estos datos fueron utilizados para entrenar los algoritmos de las redes neuronales artificiales. Así mismo, se utilizó la misma base de datos de la concesión 2 para evaluar las predicciones generadas por las redes neuronales artificiales.

Se probaron 10 tipos de algoritmos diferentes, estableciendo como variables de entrada (variables independientes) a las variables climáticas e índices de competencia y como variable de salida (variable dependiente) al volumen de los árboles. Se establecieron tres índices de competencia, en la red neuronal fue entrenado 5 veces por cada índice de competencia, estableciendo así 15 modelos de redes neuronales artificiales por cada algoritmo. Se estableció un total de 150 modelos de redes neuronales artificiales y finalmente se escogió un modelo por cada índice de competencia y algoritmo, estableciendo 30 modelos de redes neuronales artificiales.

Se experimentaron con 10 tipos diversos de algoritmos, utilizando variables climáticas e índices de competencia como variables de entrada (variables independientes) y el volumen de los árboles como la variable de salida (variable dependiente). Para cada uno de los tres índices de competencia, se entrenó la red neuronal en cinco iteraciones, lo que resultó en 15 modelos de redes neuronales artificiales para cada algoritmo. En total, se generaron 150 modelos de redes neuronales artificiales. Posteriormente, se seleccionó un modelo representativo por cada índice de competencia y algoritmo, culminando en un conjunto final de 30 modelos de redes neuronales artificiales. El total de modelos generados se puede observar en el anexo 4.

Tabla 13

Desempeño de los indicadores estadísticos de 30 modelos de redes neuronales artificiales en predicciones de volumen de árboles

| Modelo | Algoritmo | Índice de competición | R | RQEM (%) | BIAS |
|---------------|------------------------|------------------------------|----------|-----------------|-------------|
| RNA1 | RPROP+ | IID1 | 0,9207 | 23,4773 | 0,5638 |
| RNA2 | RPROP+ | IID2 | 0,9224 | 23,3540 | 0,5874 |
| RNA3 | RPROP+ | IID3 | 0,9169 | 23,9603 | 0,5400 |
| RNA4 | Backpropagation | IID1 | 0,9221 | 23,9093 | 0,7762 |
| RNA5 | Backpropagation | IID2 | 0,9226 | 23,0457 | 0,5020 |
| RNA6 | Backpropagation | IID3 | 0,9172 | 24,6240 | 0,8009 |
| RNA7 | Quick propagation | IID1 | 0,9181 | 23,6614 | 0,5044 |
| RNA8 | Quick propagation | IID2 | 0,9221 | 23,2464 | 0,5507 |
| RNA9 | Quick propagation | IID3 | 0,9155 | 24,1674 | 0,5692 |
| RNA10 | Algoritmo genético | IID1 | 0,9075 | 107,7073 | 9,0063 |
| RNA11 | Algoritmo genético | IID2 | 0,7316 | 85,5390 | 6,5762 |
| RNA12 | Algoritmo genético | IID3 | 0,9146 | 57,2255 | -0,6521 |
| RNA13 | Neat | IID1 | 0,9057 | 25,5448 | 0,5984 |
| RNA14 | Neat | IID2 | 0,9228 | 23,1226 | 0,5309 |
| RNA15 | Neat | IID3 | 0,9146 | 24,5066 | 0,6110 |
| RNA16 | Hyperneat | IID1 | 0,9220 | 24,6487 | 0,8848 |
| RNA17 | Hyperneat | IID2 | 0,9224 | 23,2805 | 0,5859 |
| RNA18 | Hyperneat | IID3 | 0,9174 | 24,6403 | 0,7716 |
| RNA19 | RBF Neural Network | IID1 | 0,9244 | 22,9469 | 0,5652 |
| RNA20 | RBF Neural Network | IID2 | 0,9244 | 22,9469 | 0,5652 |
| RNA21 | RBF Neural Network | IID3 | 0,9244 | 22,9469 | 0,5652 |
| RNA22 | Support VectorMachine | IID1 | 0,9130 | 24,2107 | 0,4502 |
| RNA23 | Support VectorMachine | IID2 | 0,9119 | 24,2681 | 0,2853 |
| RNA24 | Support Vector Machine | IID3 | 0,9104 | 24,5378 | 0,4544 |
| RNA25 | Elman | IID1 | 0,9206 | 23,3738 | 0,5261 |
| RNA26 | Elman | IID2 | 0,9210 | 23,3601 | 0,4888 |
| RNA27 | Elman | IID3 | 0,9151 | 23,9552 | 0,4605 |
| RNA28 | Jordan | IID1 | 0,9150 | 24,2644 | 0,5730 |
| RNA29 | Jordan | IID2 | 0,9220 | 23,3233 | 0,5637 |
| RNA30 | Jordan | IID3 | 0,9143 | 24,2626 | 0,5400 |

Nota. Se visualiza los estadísticos de ajuste de los diferentes modelos de redes neurales (RNA). Fuente: elaborado de la base de datos de las Concesiones 1, (Anexo 4)

La tabla 13, muestra los indicadores estadísticos de desempeño de los 30 modelos de redes neuronales artificiales. En este conjunto, los valores de R oscilan entre 0,7316 y 0,9244. Los valores de RECM % se encuentran entre 22,9469 % y 107,7073 %. Los modelos con valores extremadamente altos, como RNA10 y RNA11, sugieren una discrepancia significativa entre las predicciones y los valores reales, lo que indica una baja precisión en

esos casos particulares. Los valores de BIAS varían entre -0,6521 y 9,0063. Aquellos modelos con BIAS cercano a cero tienen una menor tendencia a cometer sesgos sistemáticos en sus predicciones.

En términos generales, se observa una variabilidad en el desempeño de los modelos, donde algunos muestran un alto grado de precisión (R cercano a 1 y RECM % bajo), mientras que otros tienen un desempeño deficiente con altos errores relativos y sesgos pronunciados. La presencia de modelos con R elevados y RECM % bajos indica una buena capacidad predictiva, sin embargo, los indicadores estadísticos no bastan para seleccionar un modelo y tomar decisiones, por ello también fueron analizados sus dispersiones de clases de errores.

En el anexo 5, se presenta la distribución de las clases de error para los 30 modelos seleccionados (Anexo 5). Para determinar cuál modelo se ajusta mejor a los datos predictivos, se consideraron los indicadores estadísticos junto con la concentración de datos en la clase de error de 0 %. En este sentido, el modelo RNA26 destaca al concentrar un 15 % de los datos en la clase de error 0 %, mostrándose como el más adecuado para su aplicación práctica. No obstante, el modelo RNA5 también exhibe condiciones favorables para su uso, al presentar una concentración del 14 % de los datos en la misma clase de error de 0 %. Ambos modelos presentan buenos performances de los indicadores estadísticos.

4.4.3. Análisis comparativo de las predicciones por el modelo potencial y las redes neuronales artificiales

Tabla 14

Comparación del desempeño de los indicadores estadísticos entre modelos de redes neuronales artificiales y modelo potencial en predicciones de volumen de árboles

| Modelo | Algoritmo | Índice de competición | Variables climáticas | R | RQEM (%) | BIAS |
|-----------|----------------|-----------------------|--|--------|----------|--------|
| RNA26 | Elman | IID2 | Precipitación Total Mensual (mm), Temperatura Máxima Promedio Mensual (C), Temperatura Mínima Promedio Mensual (C), Temperatura Promedio Mensual (C), Humedad Relativa Promedio Mensual (H), Evaporación Total Mensual (mm) | 0,9210 | 23,3601 | 0,4888 |
| Potencial | No incorporado | No incorporado | No incorporado | 0,9268 | 22,1961 | 0,3566 |

Nota. Se muestra los valores de ajuste del valor estimado y predictivo (R, RQEM y BIAS). Fuente: elaborado de la base de datos de las Concesiones 1, (Anexo 4).

La tabla 14, muestra los desempeños de los indicadores estadísticos para la red neuronal seleccionada y para el modelo potencial. El modelo RNA26, utiliza el algoritmo Elman y considera el índice de competición IID2 junto con múltiples variables climáticas, como la precipitación total mensual, las temperaturas máximas, mínimas y promedio mensuales, la humedad relativa y la evaporación total mensual. Presenta un coeficiente de correlación (R) de 0,9210, un error cuadrático medio relativo (RQEM %) de 23,3601 y un sesgo (BIAS) de 0,4888.

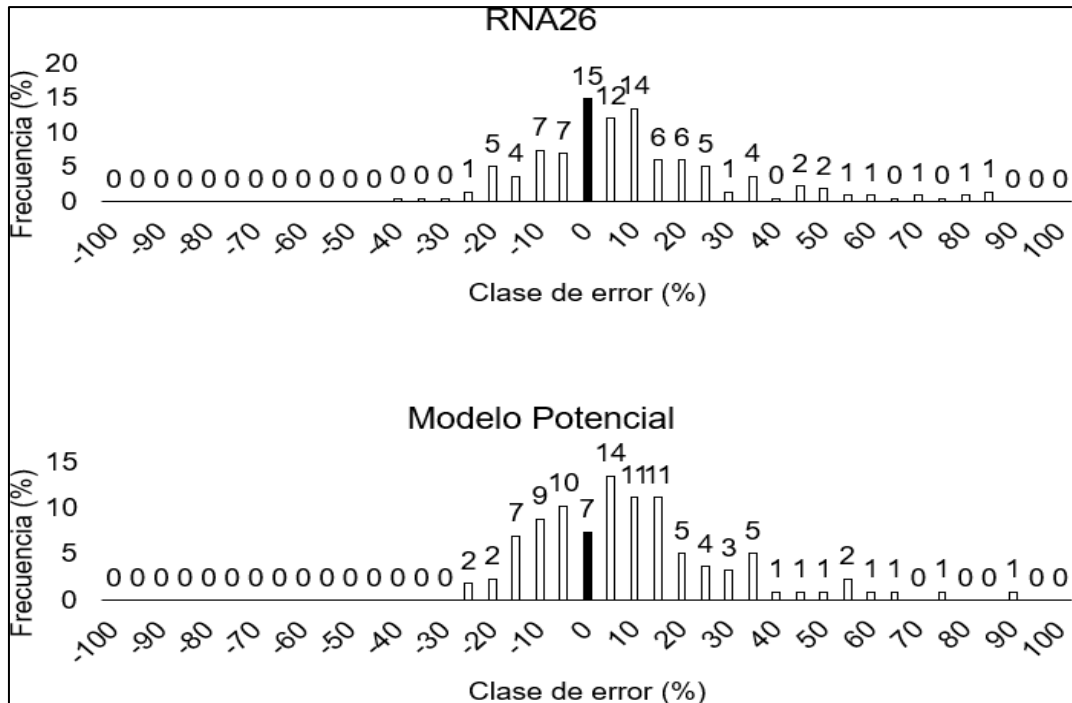
El modelo potencial basado en el método de regresión matemática no incorpora índices de competición ni variables climáticas específicas. A pesar de ello, muestra un coeficiente de correlación (R) ligeramente más alto, alcanzando 0,9268, un error cuadrático medio relativo (RQEM %) menor de 22,1961 y un sesgo (BIAS) de 0,3566.

En términos generales, el modelo potencial sin considerar índices de competición ni variables climáticas específicas parece tener un rendimiento ligeramente superior en términos de correlación y error cuadrático medio relativo. Sin embargo, para análisis de datos forestales, los indicadores estadísticos no son suficientes para tomar decisiones, y perjudica al modelador en el entendimiento práctico. Es importante considerar que el modelo RNA26 ofrece información más detallada al incorporar datos climáticos y de competición, lo que podría ser crucial en aplicaciones prácticas donde se necesite una comprensión más profunda de los factores que influyen en las predicciones. Es por ello por lo que se analizaron las distribuciones de clases de errores.

Al analizar las distribuciones de las clases de error entre el modelo RNA26 y el modelo potencial, emerge una disparidad notable en la concentración de datos en la clase de error de 0 %. El modelo RNA26 exhibe una concentración del 15 % de los datos en esta clase, evidenciando una presencia significativamente mayor en comparación con el modelo potencial, que muestra una concentración del 7 % en la misma categoría. Esta diferencia destaca la robustez del modelo RNA26 al capturar una proporción más sustancial de predicciones precisas, identificadas con la clase de error de 0 %, en contraposición al modelo potencial. Este fenómeno subraya la capacidad del RNA26 para generar predicciones más cercanas a los valores reales en comparación con el modelo potencial, ofreciendo una visión más precisa y confiable en la predicción del volumen de los árboles (Figura 9).

Figura 9

Distribución de las clases de error para los valores predictivos de la red neuronal artificial seleccionada y el modelo potencial



Nota. Se visualiza la distribución de los residuos de la estimación y predicción más adecuado, teniendo una distribución más normalizada el caso de la predicción.

4.5. Discusión

El proyecto de investigación se adentró en la mejora de las predicciones relacionadas con el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke, especie de importancia en la región de Mariscal Cáceres - San Martín. Para alcanzar esta meta, se empleó una estrategia integral que involucra el uso de modelos, incluyendo tanto el modelo potencial como redes neuronales artificiales (RNA). Se destaca el despliegue de una RNA que integra un amplio espectro de variables, tales como medidas dasométricas, datos climáticos e índices de competencia, buscando capturar la complejidad de las interacciones en este contexto forestal específico.

El enfoque no solo se limitó al desarrollo de la red neuronal, sino que también se centró en identificar algoritmos óptimos que permitan ajustar y optimizar esta RNA para lograr predicciones más precisas. Además, se realizó una validación estadística exhaustiva para respaldar y verificar la robustez de las predicciones volumétricas obtenidas a través de las redes neuronales y el modelo potencial.

Los estudios relacionados con temáticas similares a la presente investigación aún están en desarrollo, variando en las técnicas y análisis empleados. Si bien hay una falta de estudios que hayan explorado técnicas comparables, se pueden encontrar investigaciones que se enfocan en el uso de la regresión matemática, particularmente el modelo potencial. Por ejemplo, un estudio examinó la estimación del diámetro, altura y volumen de *Quercus laurina* en Ixtlán, Oaxaca, utilizando el diámetro del tocón como variable predictora. Este análisis reveló la capacidad de generar ecuaciones confiables para estimar estas medidas a partir del diámetro del tocón. Específicamente, el modelo potencial mostró una alta bondad de ajuste para la estimación de la altura y el volumen, presentando coeficientes de determinación (R^2) normal y ajustado de 0,98 y 0,98 respectivamente, y el valor de la raíz del error cuadrático medio fue de 0,23 (Martínez-López & Acosta-Ramos, 2014).

En contraste, en nuestra investigación, el modelo potencial también exhibió una alta correlación, con un coeficiente de 0,92 y un error cuadrado medio del 22 %. Sin embargo, a diferencia de este estudio referencial, nuestra validación se basó en predicciones aplicadas a una región diferente a la de los datos de ajuste originales. Asimismo, analizamos la distribución de errores mediante clases de errores, lo que sugiere una posible baja concentración de datos en la clase de 0 %, similar a la observada en nuestro estudio.

El modelo potencial también fue seleccionado como el mejor modelo para estimar el volumen total del árbol a partir del diámetro del tocón para cinco especies de pino estudiadas en El Salto, Durango, México. Además, los autores destacan que los modelos utilizados pueden ser utilizadas para calcular el volumen de árboles cortados que no fueron incluidos en un inventario anterior, así como para evaluar el volumen de árboles robados (Corral-Rivas et al., 2007).

En otro estudio relacionado, se proporcionaron modelos matemáticos fiables para estimar el diámetro normal, altura total y volumen del fuste de especies forestales también en Durango, utilizando como base el diámetro del tocón. Estos modelos mostraron excelentes ajustes estadísticos y fueron considerados herramientas útiles para el inventario y manejo de las poblaciones forestales analizadas. Específicamente, el estudio identificó el modelo potencial en su forma logarítmica como el más efectivo, con un coeficiente de determinación ajustado superior al 90 % y un error cuadrado medio promedio de 0,20 para todas las especies estudiadas (Barraza et al., 2012). En nuestra investigación, al igual que en este estudio de referencia, resaltamos la importancia de validar los modelos con muestras de datos independientes y considerar múltiples parámetros estadísticos para seleccionar los modelos más

adecuados.

La interpretación adecuada de los resultados estadísticos es esencial para comprender el desempeño de los modelos. Es fundamental no solo observar los valores numéricos, sino también comprender su significado contextual y su aplicabilidad práctica. La selección de modelos para aplicaciones prácticas debe basarse en una comprensión integral de los datos, la naturaleza del problema y la idoneidad de los modelos evaluados. La toma de decisiones informadas se logra al considerar no solo la precisión del modelo, sino también su capacidad para generalizar y adaptarse a diferentes contextos (Campos & Leite, 2017).

En entornos forestales, la competencia es una interacción entre árboles que se produce por la lucha por recursos limitados, como la luz, el agua, los nutrientes y el espacio. Esta lucha puede afectar negativamente a la supervivencia, el crecimiento y la reproducción de los individuos en cuestión. La competencia es un proceso ecológico fundamental que desempeña un papel importante en la dinámica de las poblaciones forestales. Puede influir en la composición, estructura y diversidad de las comunidades forestales (Begon & Townsend, 2023).

La incorporación práctica de índices de competición en regresiones matemáticas aún se enfrenta a obstáculos, principalmente debido a la falta de correlación con las variables dependientes y a discrepancias con las suposiciones estadísticas, esto sucede también con diversas variables climáticas. Varios investigadores han subrayado la importancia de considerar tanto variables bióticas como abióticas en los procesos de modelado en entornos forestales. Como resultado, se han explorado otras técnicas, como las redes neuronales artificiales, con el propósito de lograr una consideración más amplia de diversas variables en estos contextos.

Bajo este contexto, la inclusión del índice de competición independiente a distancia, así como variables climáticas, como variables independientes en el modelamiento, ha mostrado buenos resultados en las estimaciones y predicciones. Un estudio, presenta un modelo de redes neuronales artificiales para predecir la supervivencia y mortalidad de árboles en la selva atlántica en Brasil. El modelo utiliza variables dendrométricas, variables climáticas y el índice de competición para predecir la supervivencia y mortalidad de árboles individuales. Los resultados muestran que el modelo de redes neuronales artificiales tiene una precisión superior al 99 % en la clasificación de árboles supervivientes y no supervivientes, concluyendo que la inclusión de variables climáticas mejora la precisión de la predicción

(Rocha et al., 2018).

En el estudio, la implementación de la red neuronal con variables dendrométricas, climáticas e índices de vegetación, en conjunto con la selección adecuada de algoritmos y la validación estadística contribuyeron significativamente a mejorar las predicciones en la relación entre el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* (Ducke) Ducke. Esta mejora es crucial para una gestión forestal más precisa y efectiva en la región de Mariscal Cáceres - San Martín. Sin embargo, el modelo potencial en términos prácticos es una salida rápida en la obtención de resultados, siendo ventajosa por solo utilizar variables dendrométricas.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

El análisis del Inventario Forestal permitió identificar tendencias y patrones en la distribución de especies y densidades poblacionales del bosque en el área de estudio, se inventariaron un total de 1 666 árboles de *Cedrelinga cateniformis*. El análisis del índice de competición entre especies vegetales proporcionó información sobre las relaciones competitivas en el área de estudio. La inclusión de estas variables, así como los datos climáticos, en modelos predictivos mejoró la comprensión de estas relaciones, lo que es fundamental para una gestión forestal efectiva.

El análisis estadístico y la validación de las predicciones volumétricas de *Cedrelinga cateniformis* (Ducke) Ducke mediante redes neuronales artificiales permitieron verificar la robustez y la confiabilidad del modelo. Esta validación aportó una comprensión más profunda de la precisión y la capacidad predictiva del modelo en el contexto de la relación volumen de fuste – diámetro del tocón.

La evaluación y análisis comparativo de la eficacia del Modelo Potencial y las Redes Neuronales Artificiales en la predicción demostraron la importancia de considerar diferentes métricas de ajuste y distribuciones de clases de errores, en el modelo potencial se obtuvo un valor de R igual a 0,9268; y con la RNA26, se obtuvo un valor de R igual a 0,9210.

5.2. Recomendaciones

Ampliar el estudio para incluir otras especies forestales y explorar cómo las redes neuronales artificiales (RNA) pueden mejorar las predicciones de relaciones entre el volumen del fuste y el diámetro del tocón en diferentes especies.

Investigar cómo la inclusión de variables adicionales, como características dasométricas, climáticas, edáficas y topográficas, puede mejorar aún más la precisión de las predicciones en diferentes contextos forestales y para diversas especies.

Realizar estudios longitudinales que permitan evaluar cómo estas relaciones pueden cambiar con el tiempo y bajo diferentes condiciones ambientales y de manejo.

Aplicar el enfoque metodológico utilizado en este estudio a otras especies forestales de interés económico o ecológico para mejorar las estimaciones de sus características dendrométricas.

Evaluar la transferibilidad de los modelos desarrollados en este estudio a otras especies forestales, considerando las diferencias en las relaciones entre el volumen del fuste y el diámetro del tocón entre especies.

Integrar los resultados de este estudio en la formulación de planes de manejo forestal, considerando la capacidad de las RNA para mejorar las predicciones sobre las relaciones entre el volumen del fuste y el diámetro del tocón.

Incorporar un monitoreo continuo de variables dendrométricas, climáticas, edáficas y topográficas en los planes de manejo forestal para comprender mejor las interrelaciones en los ecosistemas forestales y mejorar la gestión sostenible de los recursos forestales.

CAPÍTULO VI

REFERENCIAS BIBLIOGRÁFICAS

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-94463-0>
- Aline, E. M. de A., Ana, C. de A. S., Mayra, L. M. da S., Daniel, H. B. B., Carlos, P. B. S., Jose, M. G., & Helio, G. L. (2018). Use of artificial neural networks to assess yield projection and average production of eucalyptus stands. *African Journal of Agricultural Research*, 13(42), 2285–2297. <https://doi.org/10.5897/ajar2017.12942>
- Baluarte-Vásquez, J. R., & Alvarez-Gonzales, J. G. (2015). Modelamiento del crecimiento de tornillo *Cedrelinga catenaeformis* Ducke en plantaciones en Jenaro Herrera, Departamento de Loreto, Perú. *Folia Amazónica*, 24(1), 21. <https://doi.org/10.24841/fa.v24i1.57>
- Bayat, M., Ghorbanpour, M., Zare, R., Jaafari, A., & Thai Pham, B. (2019). Application of artificial neural networks for predicting tree survival and mortality in the Hyrcanian forest of Iran. *Computers and Electronics in Agriculture*, 164. <https://doi.org/10.1016/j.compag.2019.104929>
- Begon, M., & Townsend, C. R. (2023). *Ecología: de individuos a ecosistemas*. Artmed editora.
- Binoti, D. H. B. (2012). *Computer systems applied to forest management* [Tese (Doutorado em Manejo Florestal; Meio Ambiente e Conservação da Natureza; Silvicultura; Tecnologias Utilização de), Universidade Federal de Viçosa]. <https://locus.ufv.br/handle/123456789/576>
- Brienen, R. J. W., & Zuidema, P. A. (2006). The use of tree rings in tropical forest management: Projecting timber yields of four Bolivian tree species. *Forest Ecology and Management*, 226(1–3), 256–267. <https://doi.org/10.1016/j.foreco.2006.01.038>
- Burkhardt, H. E., & Tomé, M. (2012). *Modeling Forest Trees and Stands*. Springer Netherlands. <https://doi.org/10.1007/978-90-481-3170-9>
- Bylin, C. V. (1982). *Volume Prediction from Stump Diameter and Stump Height of Selected Species in Louisiana*. US Department of Agriculture, Forest Service, Southern Forest Experiment Station.
- Campos Zumaeta, L. E. (2009). *Dendrocronología en árboles de Tornillo, Cedrelinga cateniformis Ducke (Fabaceae), del Centro de Investigaciones Jenaro Herrera en el noreste de la Amazonia, Región Loreto – Perú*. Universidad Nacional Agraria la

Molina.

Campos, J. C. C., & Leite, H. G. (2017). *Forest measurement: Questions and answers* (5th Ed). UFV.

Casas, G. G., Fardin, L. P., Silva, S., de Oliveira Neto, R. R., Breda Binoti, D. H., Leite, R. V., Ramos Domiciano, C. A., de Sousa Lopes, L. S., da Cruz, J. P., dos Reis, T. L., & Leite, H. G. (2022). Improving Yield Projections from Early Ages in Eucalypt Plantations with the Clutter Model and Artificial Neural Networks. *Pertanika Journal of Science and Technology*, 30(2), 1257–1272. <https://doi.org/10.47836/pjst.30.2.22>

Casas, G. G., Gonzáles, D. G. E., Villanueva, J. R. B., Fardin, L. P., & Leite, H. G. (2022). Configuration of the Deep Neural Network Hyperparameters for the Hypsometric Modeling of the *Guazuma crinita* Mart. in the Peruvian Amazon. *Forests*, 13(5), 697. <https://doi.org/10.3390/f13050697>

Castellanos Niño, Y., & Marco Renau, J. (2023). *Optimización del aprovechamiento de productos maderables en el departamento del Guaviare. Documento CEDE, (2023-11)* [Universidad de los Andes]. <https://ssrn.com/abstract=4442023>

Castro, R. V. O., Soares, C. P. B., Leite, H. G., de Souza, A. L., Martins, F. B., Nogueira, G. S., & de Oliveira, M. L. R. (2020). Projeção do diâmetro e altura de árvores em uma floresta estacional semidecidual por meio de redes neurais artificiais. *Scientia Forestalis*, 48(125), e3056.

Castro, R. V. O., Soares, C. P. B., Martins, F. B., & Leite, H. G. (2013). Growth and yield of commercial plantations of eucalyptus estimated by two categories of models. *Pesquisa Agropecuária Brasileira*, 48(3), 287–295. <https://doi.org/10.1590/S0100-204X2013000300007>

Cordeiro, M. A., Arce, J. E., Guimarães, F. A. R., Bonete, I. P., Silva, A. V. D. S., Abreu, J. C. D., & Binoti, D. H. B. (2022). Estimativas volumétricas em povoamentos de eucalipto utilizando máquinas de vetores de suporte e redes neurais artificiais. *Madera y bosques*, 28(1).

Corral-Rivas, J. J., Barrio-Anta, M., Aguirre-Calderón, O. A., & Diéguez-Aranda, U. (2007). Use of stump diameter to estimate diameter at breast height and tree volume for major pine species in El Salto, Durango (Mexico). *Forestry*, 80(1), 29–40. <https://doi.org/10.1093/forestry/cpl048>

Cuevas, X. G., Ramos, J. H., Ramos, A. H., Quiñonez Barraza, G., Carlos, J., Urías, T., Geraldine, G., & Espinoza, G. (2017). Prediction of the normal diameter, height and volume from the stump diameter in tropical species. *Revista Mexicana de Ciencias*

Forestales, 8(43).

- Da Cunha Neto, E. M., Bezerra, J. C. F., de Miranda, L. C., do Mar, A. L., Vaz, M. M., da Silva Melo, M. R., & da Castro Rocha, J. E. (2019). Kozak model and artificial neural networks in eucalyptus fuser sharing estimate. *Revista de Engenharia e Tecnologia*, 11(3), 150–158.
- Da Rocha, J. E. C., Nogueira, M. R., Da Silva Tavares, I., De Souza, J. R. M., De Sousa Lopes, L. S., & Da Silva, M. L. (2021). Configuration of artificial neural networks for height-diameter relationship of *Eucalyptus* spp. *Scientia Forestalis/Forest Sciences*, 49(132). <https://doi.org/10.18671/scifor.v49n132.08>
- Da Silva Tavares Júnior, I., da Rocha, J. E. C., Ebling, ângelo A., de Souza Chaves, A., Zanuncio, J. C., Farias, A. A., & Leite, H. G. (2019). Artificial neural networks and linear regression reduce sample intensity to predict the commercial volume of eucalyptus clones. *Forests*, 10(3). <https://doi.org/10.3390/f10030268>
- Daviran, M., Shamekhi, M., Ghezelbash, R., & Maghsoudi, A. (2023). Landslide susceptibility prediction using artificial neural networks, SVMs and random forest: hyperparameters tuning by genetic optimization algorithm. *International Journal of Environmental Science and Technology*, 20(1), 259-276.
- De Oliveira Valente, E., & Valente, G. D. F. S. (2021). Simulação de redes neurais artificiais para estimativa de volume de madeira florestal a partir do DAP. *Brazilian Journal of Animal and Environmental Research*, 4(3), 3748-3757.
- De Oliveira, B. R., da Silva, A. A. P., Teodoro, L. P. R., de Azevedo, G. B., Azevedo, G. T. de O. S., Baio, F. H. R., Sobrinho, R. L., da Silva Junior, C. A., & Teodoro, P. E. (2021). Eucalyptus growth recognition using machine learning methods and spectral variables. *Forest Ecology and Management*, 497, 119496. <https://doi.org/10.1016/j.foreco.2021.119496>
- Diéguez-Aranda, U., Dorado, F. C., Anta, M. B., & Murias, M. B. (2003). Estimación del diámetro normal y del volumen del tronco a partir de las dimensiones del tocón para seis especies forestales comerciales de Galicia. *Forest Systems*, 12(2), 131–139.
- Dos Santos, K. N. F., Rode, R., de Andrade, D. F. C., dos Santos Corrêa, K. K., & de Sousa Lopes, L. S. (2018). Ajuste de equações volumétricas e redes neurais artificiais na estimativa do volume de tauari na floresta nacional do Tapajós. *Revista Agroecossistemas*, 10(1), 1-17.
- Freitas, E. C. S. de, Paiva, H. N. de, Neves, J. C. L., Marcatti, G. E., & Leite, H. G. (2020). Modeling of eucalyptus productivity with artificial neural networks. *Industrial Crops*

- and Products*, 146, 112149. <https://doi.org/10.1016/j.indcrop.2020.112149>
- García Nieto, P. J., Martínez Torres, J., Araújo Fernández, M., & Ordóñez Galán, C. (2012). Support vector machines and neural networks used to evaluate paper manufactured using *Eucalyptus globulus*. *Applied Mathematical Modelling*, 36(12), 6137–6145. <https://doi.org/10.1016/j.apm.2012.02.016>
- Gonçalves, S. B., Fiedler, N. C., Silva, J. P. M., da Silva, G. F., da Silva, M. L. M., Minette, L. J., Pereira, D. P., Lopes, D. M. M., da Silva, E. F., Ramalho, A. H. C., Santos, J. S., Aguiar, M. O., Neto, J. de O. M., & Filho, R. N. de A. (2021). Machine learning techniques to estimate mechanised forest cutting productivity. *Southern Forests: a Journal of Forest Science*, 83(4), 276–283. <https://doi.org/10.2989/20702620.2021.1994342>
- Goycochea Casas, G. (2021). *Growth and yield modelling of eucalypt stands using regression, neural network and deep learning* [Dissertação (Mestrado em Ciência Florestal), Universidade Federal de Viçosa]. <https://locus.ufv.br/handle/123456789/27965>
- Guzmán-Santiago, J. C., Santos-Posadas, H. M. D. los, Vargas-Larreta, B., Gómez-Cárdenas, M., González-Cubas, R., Hernández-Aguilar, J. A., & Bautista-Cruz, A. (2023). Diámetro, altura y volumen en función del tocón para *Abies religiosa* en diferentes regiones de México. *Bosque (Valdivia)*, 44(2), 387–399. <https://doi.org/10.4067/s0717-92002023000200387>
- Hernández-Ramos, J., García-Cuevas, X., Hernández-Ramos, A., Tamarit Urias, J. C., Buendía-Rodríguez, E., & Reynoso-Santos, R. (2018). Modelo Para Estimar Altura Total E Índice De Esbeltez A Partir Del Diámetro Para Bursera Simaruba (L.) Sarg. En Quintana Roo, México. *Investigaciones Científicas y Agrotecnológicas para la Seguridad Alimentaria.*, 492
- Hung, B. M., Phuong, N. T. B., Doanh, L. S., & The Hai, P. (2021). Stump Diameter Characteristics And Volume Prediction For *Acacia Mangium* In Ba Vi, Vietnam. *Journal Of Forestry Science And Technology*, 11..
- Liu, L., Lim, S., Shen, X., & Yebra, M. (2020). Assessment of generalized allometric models for aboveground biomass estimation: A case study in Australia. *Computers and Electronics in Agriculture*, 175, 105610. <https://doi.org/10.1016/j.compag.2020.105610>
- Martínez-López, J., & Acosta-Ramos, A. (2014). Estimation of diameter, height and volume from the stump diameter for *Quercus laurina*, at Ixtlan, Oaxaca, Mexico. *MaderayBosques*, 20(1),59–70.

- Missouri Botanical Garden. (2024). *Cedrelinga cateniformis*.
<http://legacy.tropicos.org/Name/13008019>
- Montesinos, O. A., Montesinos, A., & Crossa, J. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. En *Multivariate Statistical Machine Learning Methods for Genomic Prediction* (pp. 379–425). Springer International Publishing.
https://doi.org/10.1007/978-3-030-89010-0_10
- Parresol, B. R. (1998). Prediction and Error of Baldcypress Stem Volume from Stump Diameter. *Southern Journal of Applied Forestry*, 22(2), 69–73.
<https://doi.org/10.1093/sjaf/22.2.69>
- Pereira, K. D., Carneiro, A. P. S., Santos, G. R. dos, Carneiro, A. de C. O., Leite, H. G., & Borges, F. P. (2021). Study of the influence of wood properties on the charcoal production: applying the random forest algorithm. *Revista Árvore*, 45.
<https://doi.org/10.1590/1806-908820210000002>
- Quiñónez, G., Cruz Cobos, F., Vargas, B., & Hernández, F. J. (2012). Estimación del diámetro, altura y volumen a partir del tocón para especies forestales de Durango. *Revista Mexicana de Ciencias Forestales*, 3(9), 23–39.
- Reis, L. P., de Souza, A. L., dos Reis Reis, P. C. M., Mazzei, L., Breda Binoti, D. H., & Leite, H. G. (2018). Prognose Da Distribuição Diamétrica Na Amazônia Utilizando Redes Neurais Artificiais E Autômatos Celulares. *Floresta*, 48(1).
- Rocha, S. J. S. S. da, Torres, C. M. M. E., Jacovine, L. A. G., Leite, H. G., Gelcer, E. M., Neves, K. M., Schettini, B. L. S., Villanova, P. H., Silva, L. F. da, Reis, L. P., & Zanuncio, J. C. (2018). Artificial neural networks: Modeling tree survival and mortality in the Atlantic Forest biome in Brazil. *Science of the Total Environment*, 645, 655–661. <https://doi.org/10.1016/j.scitotenv.2018.07.123>
- Rodríguez, E. B., Pérez, E. V., Ovalle, Á. L., & Domínguez, S. T. (2002). Aplicación de redes neuronales artificiales y técnicas SIG para la predicción de coberturas forestales. *Revista Chapingo. Serie Ciencias Forestales y del Ambiente*, 8(1), 31–37.
- Schumacher, F. X., & Hall, F. S. (1933). Logarithmic expression of timber-tree volume. *Journal of Agricultural Research*, 47(9), 719–734.
- Şenyurt, M., Ercanlı, İ., Günlü, A., Bolat, F., & Bulut, S. (2020). Artificial neural network models for predicting relationships between diameter at breast height and stump diameter: Crimean pine stands at ÇAKÜ Forest. *Bosque (Valdivia)*, 41(1), 25–34.
<https://doi.org/10.4067/S0717-92002020000100025>
- SERFOR. (2020). *Cobertura y pérdida de bosques húmedos amazónicos al 2020*.

- Sierra, Y. (2021, octubre 7). *Perú alcanza cifra de deforestación más alta en los últimos 20 años*. <https://es.mongabay.com/2021/10/peru-aumenta-deforestacion-cifras-bosques/>
- Silva, A. V. D. S., Souza, R. G. T. D., Liarte, G. V. C. C., Pinho, B. C. P., Oliveira, C. P. D., Gonzáles, D. G. E., ... & Abreu, J. C. D. (2022). Modelo de clasificación en diferentes estratos forestales en un entorno de llanura aluvial utilizando redes neuronales artificiales. *Revista Forestal Mesoamericana Kurú*, 19(45), 64-70.
- Silva, S., de Oliveira Neto, S. N., Leite, H. G., de Alcântara, A. E. M., de Oliveira Neto, R. R., & de Souza, G. S. A. (2020). Productivity estimate using regression and artificial neural networks in small familiar areas with agrosilvopastoral systems. *Agroforestry Systems*, 94(6), 2081–2097. <https://doi.org/10.1007/s10457-020-00526-1>
- Soares, C. B. S., Paula Neto, F., & Souza, A. L. (2011). *Dendrometria e inventário florestal*. (2. ed). Universidade Federal de Viçosa.
- Vásquez Rufasto, Yeiner. 2023. «Comportamiento del crecimiento inicial de la especie *Cedrelinga cateniformis* (Ducke) Ducke, utilizando diferentes dosis de superfosfato triple, en Condorcanqui, Amazonas – Perú». Universidad Nacional de Cajamarca. <http://repositorio.unc.edu.pe/handle/20.500.14074/5607>
- Vendruscolo, D. G. S., Chaves, A. G. S., Medeiros, R. A., Silva, R. S. da, Souza, H. S., Drescher, R., & Leite, H. G. (2017). Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando regressão e redes neurais artificiais. *Nativa*, 5(1). <https://doi.org/10.5935/2318-7670.v05n01a09>
- Zarate, J. , A. (2021). *Determinación de un modelo de árbol de la especie algarrobo (Prosopis pallida) y proyección de volumen aprovechado de la manera ilegal en la concesión de la universidad nacional de tumbes*. [Tesis Para Optar El Título Profesional De Ingeniero Forestal Y De Medio Ambiente]. Universidad Nacional de Tumbes.

CAPÍTULO VII
ANEXO

Anexo 1: Matriz de operacionalización de variables

| Variables | Dimensión | Indicador | Definición | Instrumento | Escala |
|------------------|--|-------------------|---|--|---------------|
| Independientes | Especie | Nombre científico | Unidad biológica de las plantas (Pinheiro, 2014). | Formato para especialista en reconocimiento de la especie | Nominal |
| | Diámetro tocón | cm | Diámetro en la base del árbol (Soares et al., 2011) | Formato digital de base de datos de la concesión Forestal Maderable N° 22-SAM/C-J-017-03 | De razón |
| | Temperatura máxima, mínima y media mensual | °C | Nivel térmico de la atmósfera | Formato digital de base de datos climáticos del SENAMHI | De razón |
| | Precipitación total mensual | mm | Agua formada en la atmósfera que regresa a la superficie terrestre en forma de lluvia | Formato digital de base de datos climáticos del SENAMHI | De razón |
| | Evapotranspiración total mensual | mm | Transformación del estado líquido a gaseoso | Formato digital de base de datos climáticos del SENAMHI | De razón |
| | Humedad relativa promedio mensual | % | Distancia vertical de un lugar en referencia a un nivel medio del mar histórico tomado como datum vertical (Vianello & Alves, 2012) | Formato digital de base de datos climáticos del SENAMHI | De razón |
| Dependientes | Índice de competición | IDD | Interacción entre especies por disputa de crecimiento en un mismo ecosistema (Glover y Holl, 1979) | Procedimiento de índices independientes a la distancia establecido por Glover y Holl en 1979 | De razón |
| | Volumen observado | V _o | Magnitud métrica de tipo escalar, que se puede definir como la extensión de un objeto en su dimensión (Soares et al., 2006) | Formato digital de base de datos de la concesión Forestal Maderable N° 22-SAM/C-J-017-03 | De razón |
| | Volumen estimado | V _e | Volumen que se aproxima a lo observado (Soares et al., 2006) | Red neuronal artificial Modelo potencia | De razón |

Anexo 2: Constancia de validación de instrumentos



UNIVERSIDAD NACIONAL DE CAJAMARCA FACULTAD DE CIENCIAS AGRARIAS ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL

CONSTANCIA DE VALIDACIÓN DE INSTRUMENTOS

Yo, Gianmarco Goycochea Casas, identificado con el DNI N° 47163515, actualmente me encuentro desempeñando una estancia doctoral en el Centro de Inteligencia Artificial y Robótica de la Universidad Tecnológica de Malasia, Kuala Lumpur.

Por medio de la presente, certifico que he llevado a cabo una revisión con propósitos de Validación de los instrumentos del Bachiller Deiber Tarrillo Alarcón, pertenecientes a la tesis titulada "Mejoras predictivas en la relación entre el volumen del fuste y el diámetro del tocón de *Cedrelinga cateniformis* Ducke en Mariscal Cáceres - San Martín".

Los instrumentos sujetos a validación abarcaron diversos aspectos, entre los que se incluyen:

- Manipulación, procesamiento y validación exhaustiva de los datos obtenidos de los inventarios forestales, asegurando su integridad y fiabilidad.
- Procesamiento metodológico y análisis estadístico, aplicados para validar el modelado, asegurando la solidez de los resultados obtenidos.

| EVALUACIÓN DE FICHAS TÉCNICAS | DEFICIENTE | ACEPTABLE | BUENO | MUY BUENO | EXCELENTE |
|--|------------|-----------|-------|-----------|-----------|
| 1. Claridad: Está formulado con un lenguaje apropiado | | | | | X |
| 2. Objetividad: Está expresado en conductas observables | | | | | X |
| 3. Actualidad: Adecuado al enfoque teórico abordado en la investigación | | | | | X |
| 4. Organización: Existe una organización lógica entre sus ítems | | | | | X |
| 5. Suficiencia: Comprende los aspectos necesarios en cantidad y calidad. | | | | X | |
| 6. Intencionalidad: Adecuado para valorar las dimensiones del tema de la investigación | | | | | X |
| 7. Consistencia: Basado en aspectos teóricos-científicos de la investigación | | | | | X |
| 8. Coherencia: Tiene relación entre las variables e indicadores | | | | | X |



UNIVERSIDAD NACIONAL DE CAJAMARCA
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL

| | | | | | | |
|--|--|--|--|--|--|---|
| 9. Metodología: La estrategia responde a la elaboración de la investigación. | | | | | | X |
|--|--|--|--|--|--|---|

Como muestra de conformidad, firmo la presente en la ciudad de Kuala Lumpur, Malasia, a los 5 días del mes de junio del año 2024.

Grado: Magíster en Ciencias

DNI: 47163515

Especialidad: Biometría Forestal

Correo electrónico: gianmarco.casas@ufv.br

DNI: 47163515

Especialista en Biometría Forestal



UNIVERSIDAD NACIONAL DE CAJAMARCA
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL

ANEXO: Ficha técnica del procedimiento de manipulación, procesamiento y validación de datos de inventarios forestales y modelado estadístico

Ficha Técnica

Nombre del Procedimiento:

Manipulación, procesamiento y validación de datos de inventarios forestales / Procesamiento metodológico y análisis estadístico para la validación del modelado.

Objetivo:

Garantizar la integridad, fiabilidad y solidez de los resultados obtenidos a partir de datos de inventarios forestales mediante procesos exhaustivos de manipulación, procesamiento y validación, así como mediante el uso de técnicas metodológicas y estadísticas para validar el modelado.

Componentes:

1. Manipulación, procesamiento y validación de datos de inventarios forestales

1.1. Descripción:

Este componente abarca el proceso completo de manipulación, procesamiento y validación de los datos recolectados durante los inventarios forestales.

1.2. Fases:

- Ingreso de datos: Ingresar los datos recolectados en una base de datos centralizada.
- Limpieza de datos: Identificar y corregir posibles errores o inconsistencias en los datos.
- Validación de datos: Verificar la integridad y fiabilidad de los datos mediante controles de calidad.
- Análisis exploratorio de datos: Realizar un análisis inicial para comprender la distribución y características de los datos.

2. Procesamiento metodológico y análisis estadístico para la validación del modelado

2.1. Descripción:

Este componente se enfoca en el procesamiento metodológico y el análisis estadístico aplicado para validar el modelado de datos.

2.2. Fases:

- Construcción del modelo: Desarrollar el modelo utilizando técnicas estadísticas y metodológicas apropiadas.
- Validación del modelo: Evaluar la solidez y precisión del modelo mediante pruebas estadísticas y técnicas de validación cruzada.
- Interpretación de resultados: Interpretar los resultados del modelado para obtener conclusiones significativas y relevantes.



UNIVERSIDAD NACIONAL DE CAJAMARCA
FACULTAD DE CIENCIAS AGRARIAS
ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL

- Selección del modelo: Seleccionar el modelo adecuado para el análisis de los datos, considerando las características específicas del estudio.

Responsable:

El responsable de este procedimiento es el equipo de investigación encargado del estudio de inventarios forestales y modelado de datos, bajo la supervisión del asesor principal del Bachiller Deiber Tarrillo Alarcón.

Recursos Necesarios:

Personal capacitado en análisis de datos forestales y modelado estadístico.

Acceso a software especializado en análisis estadístico y modelado de datos.

Datos recolectados durante los inventarios forestales.



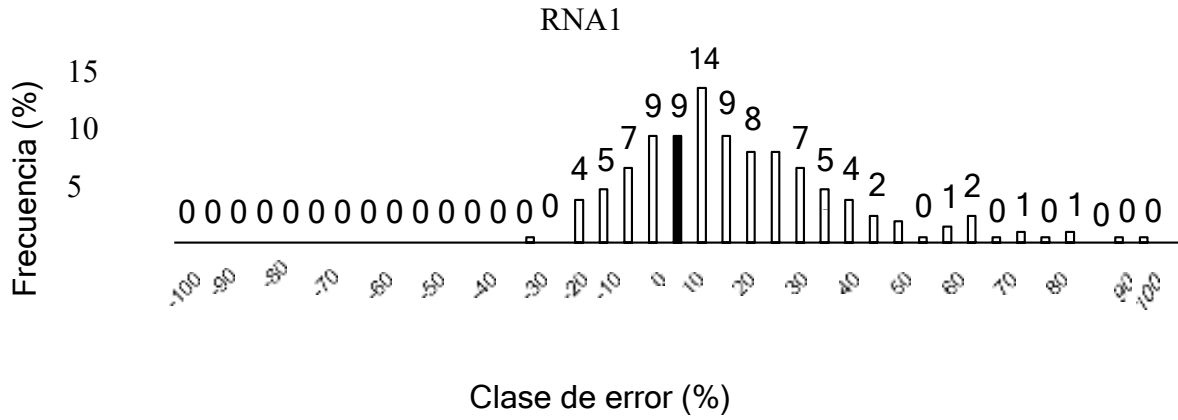
Anexo 4 Indicadores estadísticos del total de modelos generados mediante la técnica de redes neuronales artificiales





| Modelo RNA | Índice de competición | Algoritmos | Repetición de RNA | Bias | RCEM | Correlación |
|------------|-----------------------|--------------------|-------------------|---------|---------|-------------|
| 1 | IID1 | RPROP+ | RNA 1 | 0.0017 | 2.8694 | 0.9066 |
| 1 | IID1 | RPROP+ | RNA 2 | 0.0019 | 2.9538 | 0.9007 |
| 1 | IID1 | RPROP+ | RNA 3 | 0.0001 | 2.9665 | 0.8998 |
| 1 | IID1 | RPROP+ | RNA 4 | 0.0012 | 2.8765 | 0.9061 |
| 1 | IID1 | RPROP+ | RNA 5 | -0.0027 | 2.9406 | 0.9016 |
| 2 | IID2 | RPROP+ | RNA 1 | 0.0016 | 2.8074 | 0.9108 |
| 2 | IID2 | RPROP+ | RNA 2 | 0.0187 | 2.8324 | 0.9091 |
| 2 | IID2 | RPROP+ | RNA 3 | -0.0069 | 2.8187 | 0.9100 |
| 2 | IID2 | RPROP+ | RNA 4 | -0.0038 | 2.7870 | 0.9121 |
| 2 | IID2 | RPROP+ | RNA 5 | 0.0000 | 2.8095 | 0.9106 |
| 3 | IID3 | RPROP+ | RNA 1 | 0.0038 | 2.8639 | 0.9070 |
| 3 | IID3 | RPROP+ | RNA 2 | -0.0033 | 2.9091 | 0.9039 |
| 3 | IID3 | RPROP+ | RNA 3 | -0.0091 | 2.9367 | 0.9019 |
| 3 | IID3 | RPROP+ | RNA 4 | -0.0066 | 2.9411 | 0.9016 |
| 3 | IID3 | RPROP+ | RNA 5 | -0.0091 | 2.8980 | 0.9046 |
| 4 | IID1 | Backpropagation | RNA 1 | 0.1813 | 2.9738 | 0.8997 |
| 4 | IID1 | Backpropagation | RNA 2 | 0.1813 | 2.9738 | 0.8997 |
| 4 | IID1 | Backpropagation | RNA 3 | 0.1813 | 2.9738 | 0.8997 |
| 4 | IID1 | Backpropagation | RNA 4 | 0.1813 | 2.9738 | 0.8997 |
| 4 | IID1 | Backpropagation | RNA 5 | 0.1813 | 2.9738 | 0.8997 |
| 5 | IID2 | Backpropagation | RNA 1 | -0.1160 | 2.8575 | 0.9076 |
| 5 | IID2 | Backpropagation | RNA 2 | -0.1160 | 2.8575 | 0.9076 |
| 5 | IID2 | Backpropagation | RNA 3 | -0.1160 | 2.8575 | 0.9076 |
| 5 | IID2 | Backpropagation | RNA 4 | -0.1160 | 2.8575 | 0.9076 |
| 5 | IID2 | Backpropagation | RNA 5 | -0.1160 | 2.8575 | 0.9076 |
| 6 | IID3 | Backpropagation | RNA 1 | 0.2190 | 2.9469 | 0.9018 |
| 6 | IID3 | Backpropagation | RNA 2 | 0.2190 | 2.9469 | 0.9018 |
| 6 | IID3 | Backpropagation | RNA 3 | 0.2190 | 2.9469 | 0.9018 |
| 6 | IID3 | Backpropagation | RNA 4 | 0.2190 | 2.9469 | 0.9018 |
| 6 | IID3 | Backpropagation | RNA 5 | 0.2190 | 2.9469 | 0.9018 |
| 7 | IID1 | Quick propagation | RNA 1 | -0.0056 | 2.9114 | 0.9037 |
| 7 | IID1 | Quick propagation | RNA 3 | 0.0157 | 2.8928 | 0.9050 |
| 7 | IID1 | Quick propagation | RNA 4 | -0.0050 | 2.9495 | 0.9010 |
| 7 | IID1 | Quick propagation | RNA 5 | 0.1086 | 2.9445 | 0.9015 |
| 8 | IID2 | Quick propagation | RNA 1 | 0.0066 | 2.8101 | 0.9106 |
| 8 | IID2 | Quick propagation | RNA 2 | 0.0028 | 2.8230 | 0.9097 |
| 8 | IID2 | Quick propagation | RNA 3 | -0.0021 | 2.8099 | 0.9106 |
| 8 | IID2 | Quick propagation | RNA 4 | -0.0064 | 2.8471 | 0.9081 |
| 8 | IID2 | Quick propagation | RNA 5 | -0.0094 | 2.8325 | 0.9091 |
| 9 | IID3 | Quick propagation | RNA 1 | -0.0013 | 2.8776 | 0.9060 |
| 9 | IID3 | Quick propagation | RNA 2 | -0.0171 | 2.9466 | 0.9012 |
| 9 | IID3 | Quick propagation | RNA 3 | -0.0937 | 2.9106 | 0.9039 |
| 9 | IID3 | Quick propagation | RNA 4 | 0.0172 | 2.9691 | 0.8996 |
| 9 | IID3 | Quick propagation | RNA 5 | -0.0925 | 2.9083 | 0.9041 |
| 10 | IID1 | Algoritmo genetico | RNA 1 | 18.6112 | 18.6243 | 0.8985 |
| 10 | IID1 | Algoritmo genetico | RNA 2 | 22.1648 | 22.1823 | -0.7427 |
| 10 | IID1 | Algoritmo genetico | RNA 3 | 26.2717 | 26.2914 | -0.7935 |
| 10 | IID1 | Algoritmo genetico | RNA 4 | 32.4275 | 32.4505 | 0.5311 |
| 10 | IID1 | Algoritmo genetico | RNA 5 | 23.0092 | 23.0266 | 0.8843 |
| 11 | IID2 | Algoritmo genetico | RNA 1 | 27.8418 | 27.8618 | 0.2248 |
| 11 | IID2 | Algoritmo genetico | RNA 2 | 15.3453 | 15.3586 | 0.1685 |
| 11 | IID2 | Algoritmo genetico | RNA 4 | 25.6512 | 25.6741 | -0.7755 |
| 11 | IID2 | Algoritmo genetico | RNA 5 | 16.4380 | 16.4593 | 0.7207 |
| 12 | IID3 | Algoritmo genetico | RNA 1 | 18.3943 | 18.4075 | 0.7311 |





| | | | | | | |
|----|------|------------------------|-------|---------|---------|---------|
| 12 | IID3 | Algoritmo genetico | RNA 2 | 8.9794 | 8.9862 | 0.8418 |
| 12 | IID3 | Algoritmo genetico | RNA 3 | 20.5889 | 20.6067 | -0.8014 |
| 12 | IID3 | Algoritmo genetico | RNA 4 | 16.3040 | 16.3167 | -0.6082 |
| 12 | IID3 | Algoritmo genetico | RNA 5 | 36.2956 | 36.3215 | -0.8993 |
| 13 | IID1 | Neat | RNA 1 | 13.3986 | 14.6476 | 0.9004 |
| 13 | IID1 | Neat | RNA 2 | 13.4317 | 14.7102 | 0.9022 |
| 13 | IID1 | Neat | RNA 3 | 13.4471 | 14.7108 | 0.9014 |
| 13 | IID1 | Neat | RNA 4 | 13.4081 | 14.6913 | 0.9015 |
| 13 | IID1 | Neat | RNA 5 | 13.4559 | 14.7077 | 0.9015 |
| 14 | IID2 | Neat | RNA 1 | 13.4465 | 14.7307 | 0.9084 |
| 14 | IID2 | Neat | RNA 2 | 13.4059 | 14.7005 | 0.9091 |
| 14 | IID2 | Neat | RNA 3 | 13.4378 | 14.7234 | 0.9084 |
| 14 | IID2 | Neat | RNA 4 | 13.4746 | 14.7404 | 0.9078 |
| 14 | IID2 | Neat | RNA 5 | 13.4430 | 14.7278 | 0.9086 |
| 15 | IID3 | Neat | RNA 1 | 13.4185 | 14.7054 | 0.9056 |
| 15 | IID3 | Neat | RNA 2 | 13.3707 | 14.6570 | 0.9036 |
| 15 | IID3 | Neat | RNA 3 | 13.4777 | 14.7382 | 0.9002 |
| 15 | IID3 | Neat | RNA 4 | 13.4334 | 14.7112 | 0.9040 |
| 15 | IID3 | Neat | RNA 5 | 13.4465 | 14.7157 | 0.9031 |
| 16 | IID1 | Hyperneat | RNA 1 | 13.5232 | 14.7189 | 0.9011 |
| 16 | IID1 | Hyperneat | RNA 2 | 13.4752 | 14.7284 | 0.8986 |
| 16 | IID1 | Hyperneat | RNA 4 | 13.4122 | 14.6686 | 0.9002 |
| 16 | IID1 | Hyperneat | RNA 5 | 13.4722 | 14.7165 | 0.8986 |
| 17 | IID2 | Hyperneat | RNA 1 | 13.4465 | 14.7356 | 0.9084 |
| 17 | IID2 | Hyperneat | RNA 2 | 13.4710 | 14.7296 | 0.9078 |
| 17 | IID2 | Hyperneat | RNA 3 | 13.4237 | 14.7054 | 0.9088 |
| 17 | IID2 | Hyperneat | RNA 4 | 13.4704 | 14.7427 | 0.9078 |
| 17 | IID2 | Hyperneat | RNA 5 | 13.4557 | 14.7309 | 0.9084 |
| 18 | IID3 | Hyperneat | RNA 1 | 13.4526 | 14.7188 | 0.9034 |
| 18 | IID3 | Hyperneat | RNA 2 | 13.3957 | 14.6875 | 0.9025 |
| 18 | IID3 | Hyperneat | RNA 3 | 13.4368 | 14.6933 | 0.9027 |
| 18 | IID3 | Hyperneat | RNA 5 | 13.4226 | 14.6834 | 0.9032 |
| 19 | IID1 | RBF Neural Network | RNA 1 | 0.0004 | 2.9562 | 0.9005 |
| 19 | IID1 | RBF Neural Network | RNA 2 | 0.0004 | 2.9562 | 0.9005 |
| 19 | IID1 | RBF Neural Network | RNA 3 | 0.0004 | 2.9562 | 0.9005 |
| 19 | IID1 | RBF Neural Network | RNA 4 | 0.0004 | 2.9562 | 0.9005 |
| 19 | IID1 | RBF Neural Network | RNA 5 | 0.0004 | 2.9562 | 0.9005 |
| 20 | IID2 | RBF Neural Network | RNA 1 | 0.0004 | 2.9562 | 0.9005 |
| 20 | IID2 | RBF Neural Network | RNA 2 | 0.0004 | 2.9562 | 0.9005 |
| 20 | IID2 | RBF Neural Network | RNA 3 | 0.0004 | 2.9562 | 0.9005 |
| 20 | IID2 | RBF Neural Network | RNA 5 | 0.0004 | 2.9562 | 0.9005 |
| 21 | IID3 | RBF Neural Network | RNA 1 | 0.0004 | 2.9562 | 0.9005 |
| 21 | IID3 | RBF Neural Network | RNA 2 | 0.0004 | 2.9562 | 0.9005 |
| 21 | IID3 | RBF Neural Network | RNA 3 | 0.0004 | 2.9562 | 0.9005 |
| 21 | IID3 | RBF Neural Network | RNA 4 | 0.0004 | 2.9562 | 0.9005 |
| 21 | IID3 | RBF Neural Network | RNA 5 | 0.0004 | 2.9562 | 0.9005 |
| 22 | IID1 | Support Vector Machine | RNA 1 | -0.1009 | 2.9838 | 0.8987 |
| 22 | IID1 | Support Vector Machine | RNA 2 | -0.1009 | 2.9838 | 0.8987 |
| 22 | IID1 | Support Vector Machine | RNA 3 | -0.1009 | 2.9838 | 0.8987 |
| 22 | IID1 | Support Vector Machine | RNA 4 | -0.1009 | 2.9838 | 0.8987 |
| 22 | IID1 | Support Vector Machine | RNA 5 | -0.1009 | 2.9838 | 0.8987 |
| 23 | IID2 | Support Vector Machine | RNA 1 | -0.1954 | 2.8972 | 0.9055 |
| 23 | IID2 | Support Vector Machine | RNA 2 | -0.1954 | 2.8972 | 0.9055 |
| 23 | IID2 | Support Vector Machine | RNA 3 | -0.1954 | 2.8972 | 0.9055 |
| 23 | IID2 | Support Vector Machine | RNA 4 | -0.1954 | 2.8972 | 0.9055 |
| 23 | IID2 | Support Vector Machine | RNA 5 | -0.1954 | 2.8972 | 0.9055 |
| 24 | IID3 | Support Vector Machine | RNA 1 | -0.0989 | 2.9512 | 0.9010 |

| | | | | | | |
|----|------|------------------------|-------|---------|--------|--------|
| 24 | IID3 | Support Vector Machine | RNA 2 | -0.0989 | 2.9512 | 0.9010 |
| 24 | IID3 | Support Vector Machine | RNA 3 | -0.0989 | 2.9512 | 0.9010 |
| 24 | IID3 | Support Vector Machine | RNA 4 | -0.0989 | 2.9512 | 0.9010 |
| 24 | IID3 | Support Vector Machine | RNA 5 | -0.0989 | 2.9512 | 0.9010 |
| 25 | IID1 | Elman | RNA 1 | 0.0148 | 2.9605 | 0.9003 |
| 25 | IID1 | Elman | RNA 2 | 0.0136 | 2.9640 | 0.9001 |
| 25 | IID1 | Elman | RNA 3 | 0.0158 | 2.9573 | 0.9005 |
| 25 | IID1 | Elman | RNA 4 | 0.0366 | 2.9620 | 0.9002 |
| 25 | IID1 | Elman | RNA 5 | -0.0235 | 2.9642 | 0.9000 |
| 26 | IID2 | Elman | RNA 1 | -0.0289 | 2.8305 | 0.9092 |
| 26 | IID2 | Elman | RNA 2 | 0.0039 | 2.8289 | 0.9093 |
| 26 | IID2 | Elman | RNA 3 | -0.0236 | 2.8057 | 0.9109 |
| 26 | IID2 | Elman | RNA 4 | 0.0306 | 2.8302 | 0.9092 |
| 26 | IID2 | Elman | RNA 5 | -0.0050 | 2.8339 | 0.9090 |
| 27 | IID3 | Elman | RNA 1 | -0.0200 | 2.9190 | 0.9031 |
| 27 | IID3 | Elman | RNA 2 | -0.0629 | 2.9090 | 0.9039 |
| 27 | IID3 | Elman | RNA 3 | 0.0395 | 2.9159 | 0.9034 |
| 27 | IID3 | Elman | RNA 4 | -0.0709 | 2.9325 | 0.9023 |
| 27 | IID3 | Elman | RNA 5 | 0.0581 | 2.9260 | 0.9027 |
| 28 | IID1 | Jordan | RNA 1 | 0.0084 | 2.8927 | 0.9050 |
| 28 | IID1 | Jordan | RNA 2 | -0.0213 | 2.8928 | 0.9050 |
| 28 | IID1 | Jordan | RNA 3 | 0.0025 | 2.8947 | 0.9048 |
| 28 | IID1 | Jordan | RNA 4 | 0.0007 | 2.8914 | 0.9051 |
| 28 | IID1 | Jordan | RNA 5 | 0.0083 | 2.8911 | 0.9051 |
| 29 | IID2 | Jordan | RNA 1 | -0.0161 | 2.8122 | 0.9105 |
| 29 | IID2 | Jordan | RNA 2 | -0.0246 | 2.8143 | 0.9103 |
| 29 | IID2 | Jordan | RNA 3 | -0.0033 | 2.8132 | 0.9104 |
| 29 | IID2 | Jordan | RNA 4 | -0.0347 | 2.8061 | 0.9109 |
| 29 | IID2 | Jordan | RNA 5 | -0.0222 | 2.8068 | 0.9108 |
| 30 | IID3 | Jordan | RNA 1 | -0.0055 | 2.8803 | 0.9058 |
| 30 | IID3 | Jordan | RNA 2 | -0.0175 | 2.8802 | 0.9059 |
| 30 | IID3 | Jordan | RNA 3 | 0.0092 | 2.8770 | 0.9061 |
| 30 | IID3 | Jordan | RNA 4 | 0.0483 | 2.9066 | 0.9041 |
| 30 | IID3 | Jordan | RNA 5 | 0.0250 | 2.8823 | 0.9057 |


Anexo 5 Distribución de las clases de error para los valores predictivos de los 30 modelos seleccionados de las redes neuronales artificiales









RNA12




RNA13




RNA14




RNA15




RNA16




RNA17











RNA18




RNA19









RNA28



RNA29



RNA30



Anexo 6. Panel Fotográfico



Foto 1: Verificación del diámetro del tocón *Cedrelinga cateniformis* Ducke (Tornillo)



Foto 2 y 3: Verificación del volumen y diámetro de trozas de *Cedrelinga cateniformis* Ducke (Tornillo)



Foto 4 y 5: verificación de árboles en campo y delimitación de parcela de corta 4A Concesión Forestal Aserradero Tarapoto S.A.C



Foto 6: Procesamiento de datos con el equipo de investigación - oficina de la Concesión Forestal Aserradero Tarapoto – Juanjuí

Neuro

Definição das Características das Variáveis

| Variável | Não usar | Quantitativa | Qualitativa | Saida |
|-----------------------------|-------------------------------------|--------------------------|-------------------------------------|-------------------------------------|
| Libro | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Fecha | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Codigo | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Especie | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| DiametroTocon | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Volumen | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> |
| Este | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Norte | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Precipitacion_medio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Temperatura_maxima_promedio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Temperatura_minima_promedio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Temperatura_medio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Humedad_relativa_promedio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| Evaporacion_promedio | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| BD1 | <input type="checkbox"/> | <input type="checkbox"/> | <input checked="" type="checkbox"/> | <input type="checkbox"/> |
| BD2 | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| BD3 | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |
| Conjunto | <input checked="" type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> | <input type="checkbox"/> |

OK Limpapar

Foto 7: Procesamiento de datos en del inventario forestal (selección de variables)