



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

**Modeling and Optimization of Timber  
Production for a promising species - Melina -  
in Colombia using Computational Intelligence  
Techniques.**

**Jairo Alonso Tunjano**

Universidad Nacional de Colombia  
Facultad de Ingeniería  
Bogotá, Colombia  
2023

**Modeling and Optimization of Timber Production for a  
promising species -Melina- in Colombia using  
Computational Intelligence Techniques.**

Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
Inteligencia Computacional

**Jairo Alonso Tunjano**

Tesis para optar al título de:

**Doctor en Ingeniería – Sistemas y Computación**

Director

**Ph. D. Germán Jairo Hernández Pérez**

Línea de Investigación:

Inteligencia Computacional

Universidad Nacional de Colombia

Facultad de Ingeniería

Bogotá, Colombia

2023

## **AGRADECIMIENTOS**

Este trabajo se desarrolló con la orientación del Ingeniero Ph.D. Germán Jairo Hernández Pérez, profesor de la Universidad Nacional de Colombia y el Ingeniero PhD. Juan Pablo Orejuela Cabrera, profesor de la Universidad del Valle a quienes agradezco, al igual que a los docentes de la Universidad del Tolima Ingenieros Rosven Arévalo, Consuelo Arce González, Alonso Barrios y Angelo Nieto, quienes han apoyado este proceso en diferentes etapas. A la estudiante Jennifer Benavides, gracias por su ayuda incondicional.

También agradezco a las directivas de la Universidad del Tolima, quienes facilitaron los diferentes medios económicos y respaldaron la ejecución de este trabajo. De igual manera al Ingeniero Hernán Uruña quien me recibió junto con mis tesis de pregrado del programa de Ingeniería Forestal, en las instalaciones de la empresa Monterey Forestal.

Así mismo, agradezco a mi familia, en cuyo estímulo constante y amor he contado a lo largo de mis años en la academia.

# DECLARACIÓN DE OBRA ORIGINAL

Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.

JAIRO ALONSO TUNJANO

Fecha 28/02/2023

## RESUMEN

### **Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de Inteligencia Computacional**

La importancia de los bosques del mundo radica en que, junto con los océanos, son los mayores sumideros de carbono, fundamentales para mitigar el cambio climático. A pesar de su importancia, la deforestación ha reducido esta superficie forestal colocando en riesgo inminente el deterioro del medio ambiente y los beneficios obtenidos por los servicios ecosistémicos. Desde 1990 hasta 2020, se estima que se han perdido 420 millones de hectáreas de bosques en todo el mundo (FAO, 2020a).

De acuerdo a la información presentada por el DANE (2021), la producción de madera de las plantaciones forestales en nuestro país es insuficiente para cubrir las necesidades internas de esta materia prima, trayendo como consecuencia la tala indiscriminada de los bosques nativos. Colombia es un país con alto potencial forestal y específicamente en el departamento del Tolima, se necesita incentivar el sector para aumentar el establecimiento de nuevas plantaciones forestales y dotar al sector con herramientas tecnológicas de toma de decisiones que disminuyan la incertidumbre y atraigan la inversión.

La planeación para el establecimiento de una plantación forestal, debe contar con una herramienta de modelado de crecimiento y rendimiento que permita estimar la producción de madera al final de la cosecha. El mayor inconveniente que se tiene en el modelado, se debe a la intervención de los raleos, que incorporan una gran perturbación, no lineal, al sistema.

Como una alternativa en el modelado del crecimiento y rendimiento de las plantaciones y que incluya la no linealidad que genera la intervención de raleos, esta investigación tiene como objetivo el uso de herramientas de inteligencia computacional con miras a encontrar las mejores políticas de tiempo e intensidad de raleos, apoyado a la vez, con el modelado del crecimiento y la simulación del rendimiento de las plantaciones forestales, teniendo en cuenta las perturbaciones que recibe el sistema con ésta práctica silvícola y que incide directamente en la producción.

El estudio se realizó con base en la información de 5 mediciones de campo sobre 31 parcelas permanentes establecidas en plantaciones de la especie *Gmelina arborea* Roxb., ubicadas en las zonas de Bosque seco tropical del departamento del Tolima. La especie *Gmelina arborea* Roxb., es una especie asiática introducida en Colombia, siendo las características más importantes su rápido crecimiento y su adaptación a diferentes condiciones climáticas y de suelo de los bosques secos tropicales, manteniendo excelentes condiciones de resistencia que la hace una especie promisoría (Iwuoha et al., 2021).

En general, la planificación del crecimiento y rendimiento de las plantaciones forestales se basa en modelos alométricos y poco se han utilizado las herramientas de la inteligencia computacional. Para el manejo de densidad, se planifican los tiempos e intensidad de los raleos, a través de Diagramas de Manejo de Densidad que se construyen a partir de ensayos en campo sobre parcelas permanentes, con diferentes tratamientos (periodos e intensidad de raleos), que suelen durar el mismo tiempo, en años, que los periodos de aprovechamiento de la especie.

En el marco de referencia se evidenció que los modelos alométricos utilizados para el crecimiento y rendimiento de las plantaciones, no contemplan los cambios en el número de competidores, indispensable para la simulación del comportamiento del árbol y del rodal frente a los raleos. La metodología propuesta logra conseguir sus objetivos planteados, al utilizar las principales herramientas del aprendizaje automático como son: una Red Neuronal Artificial como modelo de crecimiento del árbol individual, donde se tiene en cuenta el índice de competencia; la simulación del crecimiento del rodal mediante una red de autómatas celulares que simula la interacción de cada árbol con sus vecinos. Y, finalmente un Algoritmo Genético que encuentra la mejor política de tiempos e intensidad

de las prácticas de raleo, con miras a obtener el mayor volumen de madera al momento del aprovechamiento final.

**Palabras clave:** Autómata Celular, Red Neuronal Artificial, Algoritmo Genético, Optimización, Raleo, competencia.

# ABSTRACT

## **Modeling and Optimization of Timber Production for a promising species - Melina- in Colombia using Computational Intelligence Techniques**

The importance of the world's forests lies in the fact that, along with the oceans, they are the largest carbon sinks, critical to mitigating climate change. Despite their importance, deforestation has reduced this forest area, placing environmental degradation and ecosystem service benefits at imminent risk. From 1990 to 2020, an estimated 420 million hectares of forests have been lost worldwide (FAO, 2020a).

According to information presented by DANE (2021), the production of wood from forest plantations in our country is insufficient to cover domestic needs for this raw material, resulting in the indiscriminate logging of native forests. Colombia is a country with high forestry potential and specifically in the department of Tolima, there is a need to encourage the sector to increase the establishment of new forest plantations and provide the sector with technological decision-making tools that reduce uncertainty and attract investment.

The planning for the establishment of a forest plantation must have a growth and yield modelling tool that allows estimating timber production at the end of the harvest. The major drawback in modelling is the intervention of thinning, which incorporates a large non-linear disturbance into the system.

As an alternative in the modelling of plantation growth and yield, including the non-linearity generated by the intervention of thinning, this research aims to use computational intelligence tools to find the best policies of time and intensity of thinning, supported at the same time, with the modelling of growth and simulation of the yield of forest plantations, taking into account the disturbances that the system receives with this silvicultural practice and that directly affects the production.

The study was carried out on the basis of information from 5 field measurements on 31 permanent plots established in plantations of the species *Gmelina arborea* Roxb. located in the tropical dry forest areas of the department of Tolima. The species *Gmelina arborea*

Roxb. is an Asian species introduced in Colombia, the most important characteristics being its rapid growth and its adaptation to different climatic and soil conditions of tropical dry forests, maintaining excellent conditions of resistance which makes it a promising species (Iwuoha et al., 2021).

In general, plantation forest growth and yield planning is based on allometric models and little use has been made of computational intelligence tools. For density management, thinning times and intensity are planned through Density Management Diagrams that are constructed from field trials on permanent plots, with different treatments (thinning periods and intensity), which usually last the same length of time, in years, as the harvesting periods of the species.

The reference framework showed that the allometric models used for plantation growth and yield do not take into account changes in the number of competitors, which is essential for the simulation of tree and stand behaviour in the face of thinning. The proposed methodology achieves its objectives by using the main tools of machine learning such as: an Artificial Neural Network as a model of individual tree growth, where the competition index is taken into account; the simulation of stand growth by means of a network of cellular automata that simulates the interaction of each tree with its neighbours. And, finally, a Genetic Algorithm that finds the best policy of time and intensity of thinning practices, with a view to obtaining the highest volume of wood at the time of final harvesting.

**Key words:** Cellular Automaton, Artificial Neural Network, Genetic Algorithm, Optimization, Thinning, competition.

# TABLA DE CONTENIDO

<u>AGRADECIMIENTOS.....</u>	<u>III</u>
<u>DECLARACIÓN DE OBRA ORIGINAL.....</u>	<u>IV</u>
<u>RESUMEN.....</u>	<u>V</u>
<u>ABSTRACT .....</u>	<u>VIII</u>
<u>TABLA DE CONTENIDO .....</u>	<u>X</u>
<u>LISTA DE FIGURAS.....</u>	<u>XIII</u>
<u>LISTA DE TABLAS .....</u>	<u>XVII</u>
<u>LISTA DE SÍMBOLOS Y ABREVIATURAS.....</u>	<u>XX</u>
<u>INTRODUCCIÓN .....</u>	<u>21</u>
<u>1. MARCO TEÓRICO .....</u>	<u>29</u>
<u>1.1 REVISIÓN DE LOS MODELOS EXISTENTES DE CRECIMIENTO Y RENDIMIENTO.....</u>	<u>30</u>
<u>1.2 INTERVENCIÓN SILVÍCOLA DE DENSIDAD .....</u>	<u>34</u>
<u>1.3 ÍNDICES DE COMPETENCIA .....</u>	<u>35</u>
<u>1.4 DIAGRAMAS DE MANEJO DE DENSIDAD .....</u>	<u>38</u>
<u>1.4.1 ÍNDICE DE DENSIDAD DEL RODAL (IDR) DE REINEKE .....</u>	<u>39</u>
<u>1.4.2 ÍNDICE DE ESPACIAMIENTO RELATIVO .....</u>	<u>41</u>

<b><u>1.5</u></b>	<b><u>TÉCNICAS DE LA INTELIGENCIA COMPUTACIONAL .....</u></b>	<b><u>43</u></b>
1.5.1	REDES NEURONALES ARTIFICIALES .....	44
1.5.2	RED DE AUTÓMATAS CELULARES .....	49
1.5.3	ALGORITMOS GENÉTICOS.....	51
<b><u>2</u></b>	<b><u>PROBLEMA DE INVESTIGACIÓN:.....</u></b>	<b><u>55</u></b>
<b><u>2.1</u></b>	<b><u>PROCESO DE PRODUCCIÓN .....</u></b>	<b><u>56</u></b>
2.1.1	PRIMERA ETAPA: SELECCIÓN DEL OBJETIVO ECONÓMICO.....	56
2.1.2	SEGUNDA ETAPA: SELECCIÓN DE LA ESPECIE FORESTAL.....	57
2.1.3	TERCERA ETAPA: ESTABLECIMIENTO DE PLANTACIONES .....	59
2.1.3.1	ÁREA DE ESTUDIO.....	61
2.1.3.2	MUESTREO DE PARCELAS .....	61
2.1.4	CUARTA ETAPA: MANEJO DE PLANTACIONES: .....	64
2.1.4.1.	LAS PODAS: .....	65
2.1.4.2.	LOS RALEOS O RALEOS: .....	66
2.1.5.	QUINTA ETAPA: APROVECHAMIENTO (COSECHA FINAL): .....	68
<b><u>2.2</u></b>	<b><u>DEFINICIÓN DEL PROBLEMA:.....</u></b>	<b><u>70</u></b>
<b><u>2.3</u></b>	<b><u>OBJETIVO GENERAL .....</u></b>	<b><u>74</u></b>
<b><u>2.4</u></b>	<b><u>OBJETIVOS ESPECÍFICOS:.....</u></b>	<b><u>74</u></b>
2.4.1	OBJETIVO ESPECÍFICO 1: .....	74
2.4.2	OBJETIVO ESPECÍFICO 2: .....	74
<b><u>3</u></b>	<b><u>FASES DEL DESARROLLO METODOLÓGICO.....</u></b>	<b><u>76</u></b>
<b><u>3.1</u></b>	<b><u>FASE 1. MODELO DE CRECIMIENTO DEL ÁRBOL.....</u></b>	<b><u>77</u></b>
3.1.1	MODELO DE CRECIMIENTO CON ÍNDICE DE COMPETENCIA.....	77
3.1.2	MANEJO DE LA DENSIDAD DEL RODAL.....	79
3.1.3	RNA COMO MODELO DE CRECIMIENTO .....	81
3.1.4	CONSIDERACIONES DE DISEÑO DE UNA RED NEURONAL.....	81
3.1.5	IMPLEMENTACIÓN DE LA RED NEURONAL ARTIFICIAL .....	83
3.1.6	ESPECIFICACIONES DE LA RED .....	84
3.1.7	ARQUITECTURA DE LA RED NEURONAL ARTIFICIAL .....	85
<b><u>3.2</u></b>	<b><u>FASE 2. SIMULADOR DE CRECIMIENTO DE LA PLANTACIÓN FORESTAL (AC) .....</u></b>	<b><u>87</u></b>

XII Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de Inteligencia Computacional

---

3.2.1	IMPLEMENTACIÓN DE LA RED DE AUTÓMATAS CELULARES.....	87
3.3	FASE 3. MEJORAMIENTO POLÍTICA DE MANEJO DE RALEO (AG): .....	90
<b>3.3.1</b>	<b><u>IMPLEMENTACIÓN DEL ALGORITMO GENÉTICO .....</u></b>	<b>90</b>
3.3.2	CÁLCULO DE BIOMASA Y CAPTURA DE CARBONO .....	92
<b>4</b>	<b><u>EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS .....</u></b>	<b>95</b>
4.1	ESTUDIO DE DENSIDAD DE LA ESPECIE SELECCIONADA .....	95
4.1.1	ZONAS DE DENSIDAD .....	96
4.2	MODELO EMPÍRICO DE CRECIMIENTO CON ÍNDICE DE COMPETENCIA.....	97
4.2.1	SELECCIÓN DEL ÍNDICE DE COMPETENCIA .....	97
4.2.2	MODELO DE VALIDACIÓN: .....	98
4.3	MODELO DE CRECIMIENTO A PARTIR DE UNA RED NEURONAL ARTIFICIAL .....	98
4.4	RESULTADOS DE LA SIMULACIÓN DEL RODAL CON AUTÓMATAS CELULARES.....	105
4.5	OPTIMIZACIÓN POR ALGORITMOS GENÉTICOS .....	109
4.6	VALIDACIÓN DEL MODELO .....	111
4.7	RESULTADOS DEL CÁLCULO DE BIOMASA Y CAPTURA DE CARBONO .....	113
4.8	DISCUSIÓN DE LOS RESULTADOS: .....	114
<b>5</b>	<b><u>CONCLUSIONES Y RECOMENDACIONES.....</u></b>	<b>120</b>
5.1	CONCLUSIONES.....	120
5.2	INVESTIGACIONES FUTURAS .....	121
	<b><u>REFERENCIAS.....</u></b>	<b>123</b>
	<b><u>ANEXOS .....</u></b>	<b>135</b>
	<b><u>ANEXO 1 : VALORES DE LOS INDICES .....</u></b>	<b>136</b>
	<b><u>ANEXO 2: CÓDIGO PRINCIPAL DEL AG .....</u></b>	<b>140</b>
	<b><u>ANEXO 3: REDES NEURONALES CON PYTHON .....</u></b>	<b>141</b>

## LISTA DE FIGURAS

Figura 1. Impacto de la deforestación en el cambio climático .....	21
Figura 2. Deforestación a nivel global en millones de hectáreas por año .....	22
Figura 3: Superficie deforestada en Colombia.....	24
Figura 4: Extracción anual de madera en Colombia.....	25
Figura 5: Establecimiento anual de nuevas plantaciones forestales.....	26
Figura 6: Crecimiento anual del rodal (arriba) y de árboles individual (Inferior) en relación con el valor del crecimiento. ....	40
Figura 7: Aspecto de un DMD con líneas de valores constantes (o isolíneas).....	43
Figura 8: Representación de una neurona biológica vs una neurona artificial .....	45
Figura 9: Red Neuronal Artificial Multicapa.....	46
Figura 10: Representación gráfica de las funciones de activación. ....	47
Figura 11: Representación gráfica de la característica estructural de la red de autómatas celulares bidimensional (2D). ....	50
Figura 12: Diagrama de flujo del algoritmo genético como algoritmo de optimización.....	52
Figura 13: Proceso de producción de una plantación forestal .....	56
Figura 14: Plantación de Gmelina arborea Roxb en el municipio de Armero-Guayabal (CURDN- UT).....	58

Figura 15: Patrón y distancia de siembra .....	60
Figura 16: Plantaciones de <i>Gmelina arborea</i> Roxb, en el Departamento del Tolima. ....	62
Figura 17: Izquierda: Plantación de melina con poda, Derecha: Detalle de la poda de una rama gruesa .....	65
Figura 18: Diagrama de intensidad de raleado .....	67
Figura 19: Representación de la política de raleo para la especie <i>Gmelina arborea</i> Roxb., recomendada, donde $t$ = año, $P_i$ = intensidad de raleo en porcentaje de árboles a cortar.....	67
Figura 20: Representación gráfica del espacio de estados del proceso MDP con restricciones. ....	71
Figura 21: Representación de la política de raleo para la especie <i>Gmelina arborea</i> Roxb., a encontrar, donde $t$ = año, $P_i$ = intensidad de raleo en porcentaje de árboles a cortar	71
Figura 22: Diagramas de influencia de aplicación de políticas de raleo.....	73
Figura 23:Relación entre los objetivos propuestos y su desarrollo metodológico .....	76
Figura 24: Diagrama del entrenamiento supervisado de la red neuronal artificial. ....	84
Figura 25: Información de mediciones de campo (variables dasométricas).....	85
Figura 26: Diagrama de red neuronal de una capa oculta con cinco entradas .....	86
Figura 27: Diagrama de red neuronal de una capa oculta con siete entradas .....	86
Figura 28: Diagrama de red neuronal de una capa oculta con ocho entradas.....	86
Figura 29: Distribución de los vecinos en una RAC de 2 dimensiones. ....	88
Figura 30: Estructura del cromosoma.....	91

Figura 31: Diagrama general de manejo de la densidad para plantaciones de Gmelina arborea Roxb en el Departamento del Tolima, con las respectivas zonas de densidad.....	96
Figura 32: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con cinco entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos .....	99
Figura 33: Valores de R, correlación entre los datos de simulación y los datos objetivos (red neuronal de una capa oculta con cinco entradas).....	100
Figura 34: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con siete entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos .....	101
Figura 35: . Valores de R, correlación entre los datos de simulación y los datos objetivos para los tres distintos datos de entrenamiento y el promedio de estos (red neuronal de una capa oculta con siete entradas) .....	102
Figura 36: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con ocho entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos .....	103
Figura 37: Valores de R, correlación entre los datos de simulación y los datos objetivos para los tres distintos datos de entrenamiento y el promedio de estos (red neuronal de una capa oculta con ocho entradas) .....	104
Figura 38: Comportamiento medio del diámetro.....	107
Figura 39: Volumen representado en metros cúbicos por hectárea.....	107
Figura 40: Simulación de una parcela en 2 dimensiones. Representación de la red de autómatas celulares, donde se utiliza la vecindad de Moore. ....	108
Figura 41 : representación decimal del cromosoma .....	110

Figura 42: Simulación 2D de los diámetros de los árboles de un año (Izquierda) – Simulación 2D de los diámetros de los árboles a los 12 años, antes de la cosecha final (Derecha). Parcela de 35x35 mts .....	110
Figura 43. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de una sola capa oculta .....	144
Figura 44. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de dos capas ocultas .....	144
Figura 45. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de tres capas ocultas .....	145
Figura 46. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal profunda (7 capas) .....	145

## LISTA DE TABLAS

Tabla 1: Índice de competencia independiente de la distancia .....	36
Tabla 2: Índices de competencia dependientes de la distancia. ....	37
Tabla 3: Calidad fustal del árbol.....	63
Tabla 4: Modelos de Volumen.....	64
Tabla 5: Resultado de Tratamientos Experimentales de intensidad de Raleo .....	68
Tabla 6: Arquitectura de la red propuesta.....	85
Tabla 7. Porcentaje de carbono promedio por componente y porcentaje que tiene el componente en la biomasa total en árboles de Gmelina arborea Roxb .....	93
Tabla 8. Parcelas que determinan la línea de máxima densidad, con sus respectivos índices de densidad de rodal - IDR y estimación del IDRMáx .....	95
Tabla 9: : Estadístico de ajuste del mejor modelo (lineal, potencial o exponencial) para las variables independiente “crecimiento en diámetro y altura”, e índices dependientes de la distancia de los árboles suprimidos, codominantes y dominantes.....	97
Tabla 10: Resultado del modelos 3.4,3.5,3.6.....	98
Tabla 11. Resultado del proceso de entrenamiento de la red neuronal de una capa oculta con cinco entradas.....	99
Tabla 12: Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con cinco entradas.....	99
Tabla 13: Resultado del proceso de entrenamiento de la red neuronal de una capa oculta con siete entradas.....	100

□ Tabla 14. Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con siete entradas.....	101
Tabla 15. Parámetros del proceso de entrenamiento de la red neuronal de una capa oculta con ocho entradas .....	102
Tabla 16. Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con ocho entradas .....	103
Tabla 17. Resultados del error medio cuadrático (ECM) para los datos de entrenamiento, validación y test. ....	104
Tabla 18. Resultado de la eficiencia (parámetro R) de los modelos con los datos de entrenamiento, validación y test. ....	105
Tabla 19. Tamaño de las matrices y vectores utilizados en la simulación del autómata celular.....	106
Tabla 20. Resultado de la simulación del rodal a partir del crecimiento de cada uno de los árboles de la parcela .....	108
Tabla 21: Mejor resultado obtenido en el AG.....	109
Tabla 22: Representación binaria del cromosoma. ....	110
Tabla 23: Simulación interactiva.....	112
Tabla 24. Cálculo del factor de biomasa .....	113
Tabla 25. Cálculo de carbono capturado por hectárea.....	113
Tabla 26. Arquitectura del primer modelo .....	141
Tabla 27. Arquitectura del segundo modelo .....	141
Tabla 28. Arquitectura del tercer modelo .....	142
Tabla 29. Arquitectura del cuarto modelo .....	142

Tabla 30. Estadística de los datos de entrenamiento .....	143
Tabla 31. Resultados obtenidos del modelo estadístico (ecuaciones (3.4), (3.5) y (3.6)) .....	146
Tabla 32. Resultados obtenidos de los datos de entrenamiento.....	146
Tabla 33. Comparación de los valores de ECM de los modelos .....	147

- X Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
X la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
Inteligencia Computacional
- 

## LISTA DE SÍMBOLOS Y ABREVIATURAS

### Símbolos con letras latinas

Símbolo	Término	Unidad SI	Definición
<i>A</i>	Área	m <sup>2</sup>	
<i>G</i>	Área basal	m <sup>2</sup>	
<i>DN</i>	Diámetro Normal	m	
<i>HT</i>	Altura Total	m	
<i>HC</i>	Altura Comercial	m	
<i>DAP</i>	Diámetro a la Altura del Pecho	m	
<i>dg</i>	Diametro medio cuadratico	m	

### Abreviaturas

Abreviatura	Término
<i>IS</i>	Índice de Sitio
<i>IDR</i>	Índice de Densidad de Rodal
<i>PNUF</i>	Plan Nacional de Desarrollo Forestal
<i>AC</i>	Autómata Celular
<i>AGs</i>	Algoritmos Genéticos
<i>IC</i>	Índice de Competencia
<i>IA</i>	Inteligencia Artificial
<i>RNA</i>	Red Neuronal Artificial
<i>DMD</i>	Diagrama de Manejo de Densidad
<i>IH</i>	Índice de Espaciamento Relativo
<i>RAC</i>	Red de Autómatas Celulares

## INTRODUCCIÓN

Los bosques del mundo son considerados como recursos muy importantes y fundamentales para mitigar el calentamiento global y el cambio climático. Ellos cubren aproximadamente una tercera parte de la superficie de la tierra y en ellos se encuentra la mayor parte de la biodiversidad terrestre. La importancia de la conservación de los bosques en el mundo radica en que, junto con los océanos, son los principales sumideros de carbono, mitigando el daño de los gases de efecto invernadero, especialmente de dióxido de carbono (FAO, 2022).



Figura 1. Impacto de la deforestación en el cambio climático

Fuente <https://vietnamwaterportal.com/news/climate-change-impacts-on-water-related-sectors.html>

Según información de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (Food and Agriculture Organization of the United Nations –FAO), en el año 2020 el área de los bosques ocupaba el 31% de la superficie terrestre, con cerca de 4.060

millones de hectáreas (ha). De estos bosques, 1.827 millones de hectáreas (ha) corresponden al dominio tropical (45 %) (FAO, 2020b).

A pesar de lo importante que son los Bosques para la biodiversidad y el bienestar de las personas, la deforestación ha reducido esta superficie forestal colocando en riesgo inminente el deterioro del medio ambiente y los beneficios obtenidos por los servicios ecosistémicos. Desde 1990 hasta 2020, se estima que se han perdido 420 millones de hectáreas de bosques en todo el mundo (FAO, 2020a). Para el año 2020, se calculó que se perdieron en todo el mundo unos 4,5 millones de hectáreas de bosque. La mayor deforestación se realiza, sobre todo, en Sudamérica y África, donde se encuentran los mayores bosques tropicales del mundo: el Amazonas y la selva del Congo. África registra la mayor tasa anual de deforestación: en el periodo 2010-2020 se perdieron unos 3,9 millones de hectáreas (ha) de bosque al año. Para el mismo periodo, Sudamérica tuvo una pérdida anual estimada de 2,6 millones de hectáreas (ha) de bosque.

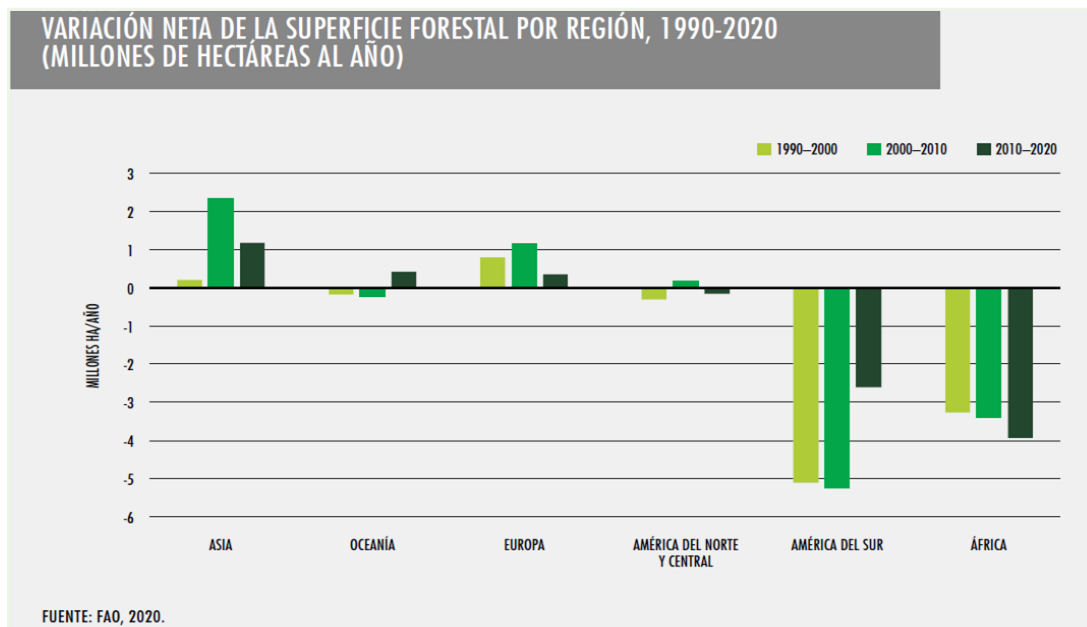


Figura 2. Deforestación a nivel global en millones de hectáreas por año

Fuente: FAO, 2020

Por el contrario, durante 2010-2020, la pérdida de bosque natural por deforestación está siendo compensada por la reforestación en Asia (1,2 millones de hectáreas (ha) por año)

y Europa (0,3 millones de hectáreas (ha) por año) (FAO, 2020b). Esta pérdida de bosque natural repercute directamente en el secuestro de carbono: las reservas mundiales de carbono forestal disminuyeron entre 1990 y 2020 de 668 Gigatoneladas a 662 Gigatoneladas (FAO, 2020a).

Las principales causas de la deforestación son el aumento de la frontera agrícola y la extracción de madera, utilizada en la industria en todo el mundo. Se estima que de los bosques naturales se extraen dos tercios de la producción total de madera (Thiffault et al., 2021).

Los bosques naturales en Colombia, para el año 2020 cubrían cerca del 52 por ciento (aprox. 59.312.277 ha) del territorio continental del país y son fundamentales en la provisión de servicios ecosistémicos (Ministerio de Ambiente y Desarrollo Sostenible, 2020).

Respecto a la deforestación, según el Departamento Nacional de Planeación, entre 2005 y 2015 en Colombia se perdieron 1.5 millones de hectáreas de bosque, durante los años 2016 y 2017 se deforestaron 178.000 y 219.000 hectáreas adicionales, respectivamente (Departamento Nacional de Planeación, 2019). En el 2014 Colombia contaba con cerca de 24,8 millones de hectáreas con aptitud forestal comercial, es decir, el 21,7% del territorio nacional; sin embargo, para 2015 solamente el 1,8% del territorio nacional, equivalente a unas 450.000 hectáreas, correspondían a plantaciones forestales comerciales establecidas. La silvicultura y la extracción de madera señalan que su contribución al PIB oscila entre el 0.2% y el 0.5%, que es aportado principalmente por el flujo de productos obtenidos mediante el aprovechamiento de los bosques naturales (Ministerio de Ambiente y Desarrollo Sostenible, 2020). El total de la madera movilizada para el año 2020 fue de 2.306.954,46 m<sup>3</sup>, este volumen está representado por 122 especies (Ministerio de Agricultura y Desarrollo Rural, 2021).

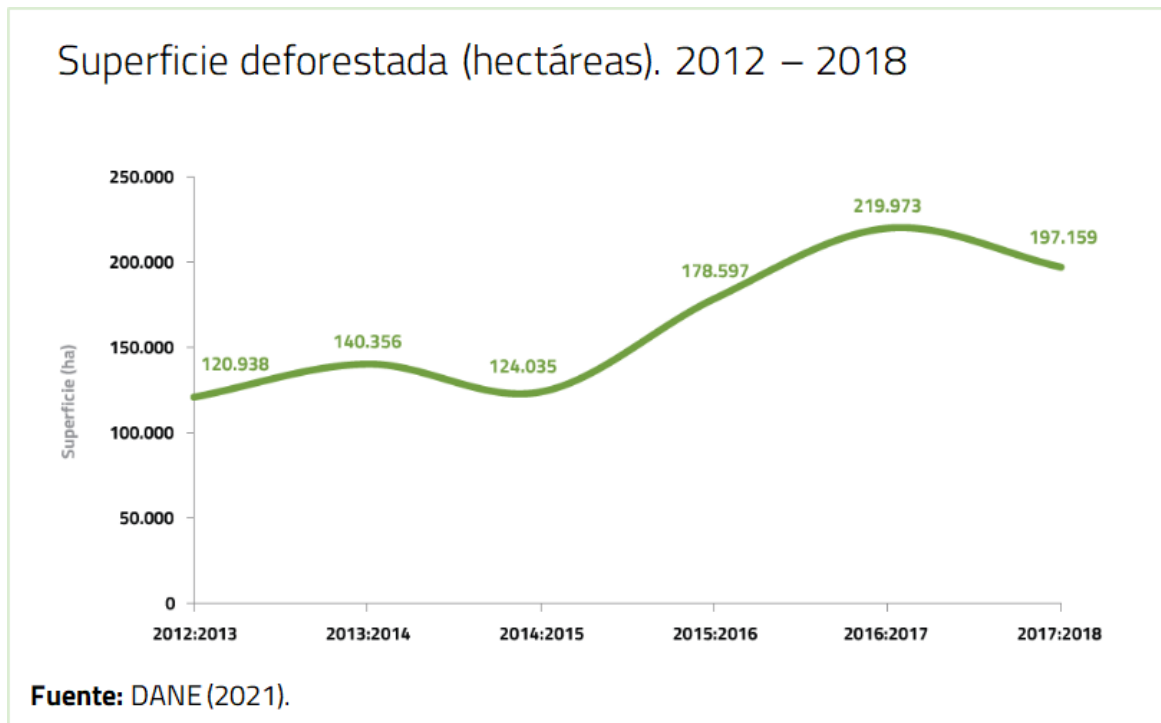


Figura 3: Superficie deforestada en Colombia

Fuente: DANE, 2021

Se estima que en Colombia la demanda de productos maderables para el año 2030, se incrementará en 4,2 millones de m<sup>3</sup> rollizos de madera equivalentes, casi el doble de la demanda para el año 2020, de la cual se exporta una mínima parte, cifras que pueden potencializarse con la aplicación de medidas efectivas (Departamento Nacional de Planeación, 2020).

Amaya Arias (2020), señala que la investigación científica en los ecosistemas boscosos tropicales es indispensable para avanzar hacia el desarrollo sostenible del sector forestal colombiano. En este sentido, el Plan Nacional de Desarrollo Forestal establece que el Estado “estimulará y promoverá la investigación científica y tecnológica y el conocimiento tradicional como elementos fundamentales para el manejo sostenible y conservación de los ecosistemas forestales” (Amaya Arias, 2020).

Ante la necesidad de madera como materia prima para diversas industrias como muebles, construcción, papel y combustible, debido a que la regeneración de los bosques naturales es relativamente lenta con tasas de crecimiento de aproximadamente 2 m<sup>3</sup>/ha/año, es

necesario incrementar las plantaciones forestales que, bajo programas de mejoramiento, plantación optimizada de las especies deseadas y aplicación de tratamientos silvícolas, suministren un mayor porcentaje de la madera requerida por la industria. Además, proporcionan otros servicios ecosistémicos como hábitats para la vida silvestre, conservación y secuestro de carbono, vitales para mitigar el cambio climático antropogénico (Dash et al., 2019), (Thiffault et al., 2021).

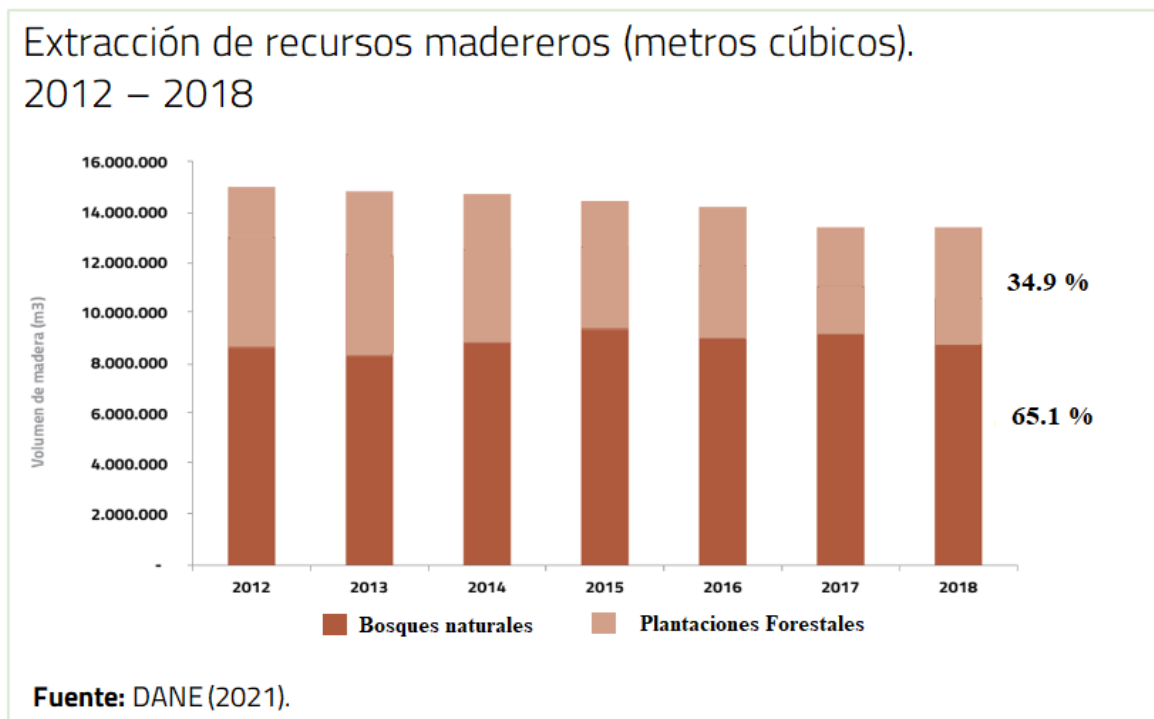


Figura 4: Extracción anual de madera en Colombia

Fuente: DANE, 2021

Los proyectos forestales productivos se formulan en horizontes de tiempo de mediano o largo plazo y, como es natural, el riesgo e incertidumbre de sufrir fluctuaciones desfavorables en los mercados madereros depende fuertemente del lapso de tiempo. Por esto, el desarrollo de paquetes tecnológicos que permitan estimar de manera confiable turnos óptimos de cosecha, rendimientos, tasas de crecimiento y retornos financieros serán un factor primordial para estimular el desarrollo forestal del país (Melo, 2015)

### El problema a resolver y la solución propuesta:

Se ha disminuido dramáticamente el establecimiento de nuevas plantaciones forestales en Colombia porque **la rentabilidad económica no es atractiva**, generando un aumento en la deforestación de bosques naturales.

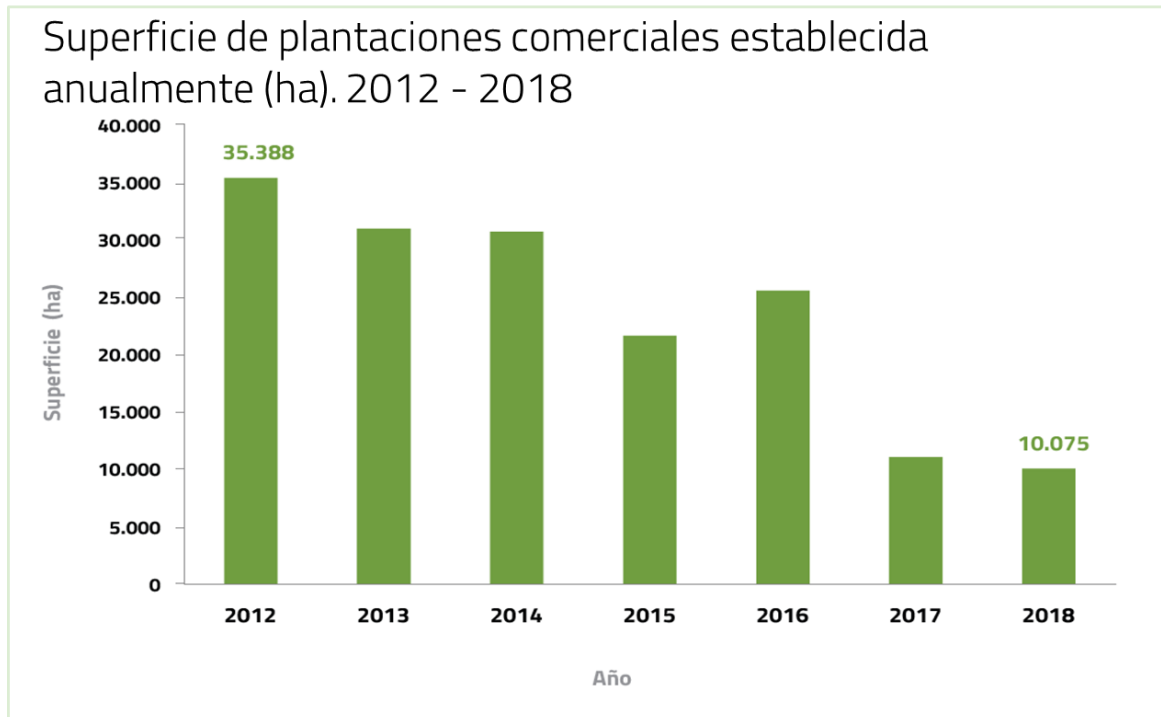


Figura 5: Establecimiento anual de nuevas plantaciones forestales.

Fuente: DANE(2021)

Se requiere, entonces, dentro del propósito de impulsar e incentivar los programas de establecimiento de plantaciones forestales para la industria, generar conocimiento técnico y científico que permita estimar con gran precisión los rendimientos futuros de las plantaciones en cuanto a bienes y servicios, al igual que su estimado tanto en cantidad como en calidad, de acuerdo con la oferta del entorno ambiental en donde se establezcan. Este logro, permitirá aumentar la confianza de inversión tanto local como extranjera, y su consecuente desarrollo sectorial. Por lo anterior, es importante para el sector no solo contar con modelos computacionales que caractericen a los rodales de forma global (modelos empíricos de regresión), sino también explorar nuevas técnicas computacionales que den

cuenta de las relaciones de sus individuos. Con ese propósito se planteó en este trabajo, el uso de las herramientas de la inteligencia computacional ('Machine Learning'), que permitan no solo modelar el crecimiento y rendimiento de las plantaciones sino también explorar la opción de optimización de los procesos de manejo de la producción madera.

El estudio se realizó a partir de 5 mediciones de campo, con intervalos de aproximadamente un año entre cada medición, sobre 31 parcelas permanentes establecidas en plantaciones de la especie *Gmelina arborea* Roxb., ubicadas en los municipios del Armero, Coello y Guamo del departamento del Tolima en zonas de Bosque seco tropical. La especie *Gmelina arborea* Roxb., es una especie asiática introducida en Colombia y es la octava especie con mayor aporte de volumen, específicamente con 57887,88 m<sup>3</sup> (Ministerio de Agricultura y Desarrollo Rural, 2021). La especie presenta dureza en la madera con una rápida tasa de crecimiento, facilidad y bajo costo de establecimiento, idónea para la industria de pulpa, papel y también para productos de madera maciza, cuyas propiedades materiales, son de permanente estudio. La *Gmelina arborea* Roxb. se adapta muy bien en los bosques secos tropicales y puede desarrollarse extensivamente donde nunca ha existido antes (Iwuoha et al., 2021), siendo las características más importantes su rápido crecimiento y su adaptación a diferentes condiciones climáticas y de suelo, manteniendo excelentes condiciones de resistencia que la hace una especie promisoría (Iwuoha et al., 2021).

Esta investigación tiene como objetivo el uso de herramientas de inteligencia computacional y aprendizaje de máquina, con miras a encontrar las mejores políticas de tiempo e intensidad de raleos, apoyado a la vez, con el modelado del crecimiento y la simulación del rendimiento de las plantaciones forestales. Los modelos de crecimiento y rendimiento planteados, tienen en cuenta la competencia que ejercen los vecinos sobre el árbol individual, lo que permite simular las perturbaciones que recibe el sistema después de las intervenciones de raleo y que incide directamente en la producción.

Para el cumplimiento del objetivo propuesto se plantea una metodología basada en técnicas de inteligencia computacional, las cuales tienen la capacidad de mapear patrones de entrada y descubrir patrones ocultos en sistemas no lineales de alta dimensión (Martins Silva et al., 2019). Su implementación se realizó mediante el modelado y simulación del crecimiento de la especie promisoría Melina (*Gmelina arborea* Roxb.). A partir de las

mediciones de campo de parcelas permanentes, se analizaron las condiciones de no linealidad y recursividad del sistema al momento de aplicar los turnos de raleo. Para este propósito se utilizaron variables de competencia intraespecífica. Mediante la simulación se obtiene el valor del volumen del árbol al final de la cosecha. Con el modelo obtenido, se estudia el comportamiento del sistema (rodal) a diferentes tiempos e intensidad de raleos, para encontrar aquellos que maximicen la producción de madera (volumen final). Su desarrollo contempla tres fases:

En la fase 1, a partir de la implementación de una Red Neuronal Artificial (RNA): se modeló el crecimiento del árbol individual considerando la competencia de los árboles vecinos como un factor determinante para el modelo.

En la fase 2. Se implementa una red de Autómatas Celulares(AC), que permiten Simular el crecimiento de la plantación forestal donde cada autómatas representa un árbol modelado por la Red Neuronal Artificial

Y finalmente una tercera fase donde se analizan, con la ayuda de un Algoritmo Genético (AG) el rendimiento de diferentes políticas de manejo de raleo para encontrar la que mayor volumen de madera se obtiene

De acuerdo a lo expuesto, se plantea la estructura de este documento de la siguiente manera: capítulo 1, presentación del Marco Teórico de Referencia; capítulo 2, en este capítulo se precisa el problema de investigación; capítulo 3, planteamiento de las fases del desarrollo metodológico; capítulo 4, presentación y discusión de los resultados obtenidos; y capítulo 5, las conclusiones y la recomendación de investigaciones futuras.

## 1. MARCO TEÓRICO

La silvicultura de bosques plantados es un sector económico complejo que depende de los datos de seguimiento de recursos y procesos. La mayoría de las operaciones forestales, como la siembra y la cosecha, están respaldadas por el uso de herramientas computacionales, y su seguimiento se ha realizado tradicionalmente mediante el uso de estudios de tiempo. Los métodos modernos de recopilación y análisis de datos que involucran diferentes tipos de plataformas y técnicas de aprendizaje automático se han estudiado últimamente con el objetivo de facilitar el proceso de gestión de datos (Castro Pérez & Borz, 2021).

Los modelos de crecimiento son una representación simplificada de un sistema real para su estudio y análisis. El modelo puede estar constituido por uno o varios gráficos, una o más tablas, un sistema de ecuaciones, o una Red Neuronal Artificial, que puede predecir el crecimiento, el rendimiento, la mortalidad, y otros cambios en la composición y estructura de un rodal bajo una amplia variedad de condiciones. Su diseño incluye elementos y relaciones suficientes para representar la dinámica del crecimiento de los bosques. En este sentido los modelos de producción y crecimiento constituyen una herramienta importante para el manejo forestal sustentable, brindando flexibilidad a la predicción en función del objetivo de producción, las especies, el manejo silvícola y las condiciones ambientales propias del sitio donde se hayan plantados los rodales (Fernández Tschieder et al., 2013).

La tendencia mundial en la construcción de modelos de crecimiento y rendimiento es hacia la construcción de modelos híbridos que incluyan efectos de cambio climático, sin embargo Salas (2016) en su estudio del estado del arte, enfatiza que en la evidencia empírica estos modelos no han mostrado mejoras predictivas respecto a modelos más simples e,

igualmente resalta que “no existen tipos de modelos mejores que otros, sino que cada cual se emplea para responder diversas preguntas de investigación o de manejo”.

## 1.1 Revisión de los modelos existentes de crecimiento y Rendimiento

La planificación forestal es uno de los componentes centrales de la silvicultura y la gestión de los ecosistemas forestales. Se necesitan dos elementos clave para la planificación forestal: modelos de crecimiento y rendimiento forestal, y modelos de optimización. La gestión forestal de los bosques plantados controla principalmente el crecimiento de la madera a través de la regulación de la densidad de rodales (Thurm & Pretzsch, 2021). En este sentido la gestión de rodales debe ofrecer información detallada sobre los regímenes óptimos de raleo (el momento, la frecuencia, el tipo de raleo) y la rotación óptima para mejorar la calidad de las decisiones de gestión forestal. Dichos estudios de manejo forestal generalmente combinan modelos de crecimiento de rodales mediante la simulación y optimización de los proceso (Xue et al., 2019). La optimización de la gestión de rodales ha sido durante mucho tiempo exigente desde el punto de vista computacional a medida que se han desarrollado modelos de crecimiento y rendimiento cada vez más detallados (Xue et al., 2019). Por lo tanto, los modelos de crecimiento son un apoyo para las decisiones de planificación forestal y la evaluación de alternativas silvícolas (Shifley et al., 2017).

En la literatura se encuentran una gran cantidad de estudios de modelos de crecimiento de masas forestales. Una síntesis del desarrollo que ha tenido la modelización de los bosques de forma cronológica la presenta el profesor J. Vanclay (2003), iniciando con el trabajo del científico alemán Georg Ludwig Hartig (1795), quien incorporó la idea del uso sustentable de los recurso del bosque y las tablas de rendimiento para su modelación, sentando las bases de la silvicultura moderna en su libro “Anweisung zur Taxation und Beschreibung der Forste, oder zur Bestimmung des Holzertrages der Wälder”; siguiendo con el modelo aritmético simplificado de Schneider (1853), destacado por haber sido muy utilizado en Europa.

En el siglo XX destaca los modelos basados en Tablas de alineación (alignment charts) especialmente el presentado por Reineke (1927); asimismo, resalta cronológicamente los siguientes trabajos de acuerdo a su implementación, dentro de los modelos de crecimiento basados en la biología, los presentados por Schumacher (1939) y por Bertalanffy (1941); las ecuaciones de crecimiento derivadas estadísticamente en los trabajos de MacKinney y Chaiken (1939); y las representaciones matriciales en los trabajos de Leslie (1945) y de Usher (1966). En relación a ecuaciones de rendimiento y crecimiento compatibles, los presentados por Buckman (1962), y por Clutter (1963); los modelos de árbol individual con el uso del computador presentados por Newnham en su tesis doctoral (1964), y su trabajo junto con Smith en el mismo año (1964). Finalmente, hace referencia a un conjunto de modelos a partir de los cuales se han desarrollado variantes que perduran hasta el presente o que han influenciado en la creación de nuevos modelos, ellos son: JABOWA (Botkin, 1993; Botkin et al., 1972); PROGNOISIS (Stage, 1973); PROGNAUS (Sterba & Monserud, 1997); NORM (Vanclay, 1989, 1994); y SORTIE (H. Deutschman et al., 1997; Pacala et al., 1993).

Por otro lado, para Pretzsch (2010) la era de la ciencia forestal, comenzó con W. L. Pfeil (1783-1859), H. Cotta (1763-1844), y G. L. Hartig (1764-1837); y destaca las décadas de 1860 y 1870, en donde Franz V. Baur (1830-1897), August V. Ganghofer (1827-1900), Karl Gayer (1822-1907) y Arthur V. Seckendorff-Gudent (1845-1886) describieron un enfoque básico para el establecimiento de investigaciones forestales a largo plazo iniciando una red de parcelas experimentales ampliamente distribuidas en los rodales forestales de Baviera. Muchas de las primeras parcelas experimentales están siendo monitoreadas aún hoy, 130 años después de su establecimiento.

Las tablas de rendimiento, con 250 años de historia, se consideran los primeros modelos basados en largos periodos de observación de parámetros a nivel de parcela (número de árboles, altura media, diámetro medio, área basal, factor de forma, incremento anual acumulativo, producción total e incremento medio anual). Las tablas de rendimiento siguen siendo la base de las herramientas de gestión forestal utilizadas actualmente por los profesionales y planificadores forestales (Kuehne et al., 2022).

En los años 60 del siglo anterior, se da comienzo a una segunda generación de modelos, que además de los datos a nivel de rodal, también tienen en cuenta la frecuencia en el

número de árboles y clases de tamaño para permitir mejores predicciones de rendimiento por clases y retorno financiero neto. Los modelos de ecuaciones diferenciales, los modelos de extrapolación de distribución y los modelos de evolución estocástica sirvieron para este propósito al abstraer la dinámica de desarrollo de los estratos de los rodales coetáneos (Pretzsch, 2010).

Se definieron modelos de árboles individuales dependientes e independientes de la posición como enfoques en los que la competencia de los rodales es modelada con y sin considerar el patrón de distribución espacial (coordenadas del árbol, distancias entre pares de árboles, parámetros de la copa), respectivamente (Pretzsch, 2010). Se describen modelos de claros que reproducen el crecimiento de árboles solitarios en parches forestales en relación con las condiciones de crecimiento promedio prevalecientes en el sitio. En estos modelos las relaciones entre las condiciones ambientales y el crecimiento son descritas parcialmente en forma estadística y se complementa con una descripción eco-fisiológica, es decir, son un modelo intermedio entre modelos estadísticos de árbol individual y modelos de procesos orientados eco fisiológicamente (Pretzsch, 2010).

Los modelos de procesos eco-fisiológicos predicen el desarrollo del árbol a partir de procesos fisiológicos primarios como la foto-producción, la respiración o la asignación de carbono. Este tipo de modelos se basan en las relaciones físicas, químicas y eco-fisiológicas básicas, tanto como sea posible, y buscan apoyo estadístico sólo para salvar la brecha de conocimiento cuando sea necesario. Con ellos se predice la producción primaria a nivel de árbol individual o nivel de rodal y proporcionan información sobre los ciclos de carbono, nitrógeno y agua, apoyando así un entendimiento y manejo integral de los ecosistemas (Pretzsch, 2010).

El análisis de los diferentes software utilizados en Europa, bajo el auspicio de Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria (INIA) muestra la pertinencia de los modelos con relación al cambio climático (Fontes et al., 2010). El trabajo de análisis enfoca su revisión agrupando los modelos en los tres tipos de modelos, que se usan en gestión forestal: Modelos empíricos (EM), bajo la óptica de cambio ambiental; Modelos basados en procesos eco-fisiológicos (PBM), que están en uso en Europa, se analizaron

teniendo en cuenta su estructura, sus entradas y sus salidas bajo la perspectiva de gestión forestal, y los Modelos híbridos (HM).

Según Shifley (2017), el ímpetu inicial para modelar la dinámica forestal fue estimar el rendimiento de la madera a lo largo del tiempo y, por lo tanto, mejorar la eficiencia de la producción de madera. La gestión forestal controla principalmente el crecimiento de la madera a través de la regulación de la densidad (Thurm & Pretzsch, 2021). Dentro de los procesos silvícolas más importantes, tendientes a lograr los objetivos comerciales que se deseen en una plantación forestal coetánea, se encuentra el manejo de la densidad, elemento clave mediante el cual los silvicultores manipulan el crecimiento y el rendimiento de los rodales (Thiffault et al., 2021). Los estudios de modelado han demostrado los beneficios financieros que se pueden obtener al enfocarse en la densidad óptima del rodal (Dash, 2019).

Thurm y Pretzsch (2021), mencionan que el manejo de la densidad de rodales es una de las medidas silvícolas más importantes la cual se produce de forma continua durante todo el desarrollo del rodal, afectando a factores y funciones ecosistémicas ecológicas, económicas y socioeconómicas. Además, destacan numerosos estudios relacionados con la densidad, entre los cuales se encuentran: análisis de medidas para la cuantificación de la densidad del rodal (Reineke, 1933; Zeide, 2005); técnicas de reducción de la densidad por raleo (Nyland, 2016); reacciones de crecimiento del rodal al raleo (Mäkinen & Isomäki, 2004); y principios básicos de las relaciones crecimiento-densidad (Assmann, 1950; Curtis et al., 1997; Langsaeter, 1941; Zeide, 2001). Destacando que uno de los hallazgos más importantes fue la relación crecimiento-densidad uniforme y su dependencia de las especies de árboles, las condiciones del sitio y la fase de desarrollo del rodal (Pretzsch, 2009).

En la literatura se emplean dos conceptos: densidad del rodal y densidad puntual. Como sugieren Lee y Choi (2019), la densidad del rodal es un término cuantitativo que describe el grado de aglomeración de tallos dentro de un área sembrada. Mientras que la densidad puntual se refiere al entorno directo de un árbol individual, es decir al entorno directo de competencia. Por su importancia, el modelado de la densidad, que permite describir sus consecuencias sobre el desarrollo forestal, es un tema clásico en la investigación del crecimiento forestal (Gadow et al., 2007; Reyes-Muñoz et al., 2011).

El uso de la Inteligencia Artificial (IA) en los modelos ambientales ha crecido con el reconocimiento de su potencial. Diferentes técnicas de la IA imitan la percepción, aprendizaje y razonamiento humano para resolver problemas complejos siendo las más utilizadas: el razonamiento basado en casos, sistemas basados en reglas, redes neuronales artificiales, algoritmos genéticos, autómatas celulares, modelos difusos, sistemas multiagente, inteligencias colectivas (enjambres), aprendizaje reforzado y los sistemas híbridos (S. H. Chen et al., 2008).

En los últimos años, con el desarrollo de la tecnología de teledetección y el análisis de big data, se han desarrollado nuevos modelos que incorporan datos satelitales y mediciones terrestres para comprender mejor las complejas interacciones entre los árboles y su entorno. Estos modelos también se utilizan para predecir los impactos del cambio climático en los ecosistemas forestales

Estos estudios dan cuenta que, una vez establecido el rodal forestal, el monitoreo de la densidad, se convierte en la principal estrategia a tener en cuenta, en la planeación y manejo de los bosques plantados.

## 1.2 Intervención silvícola de densidad

Existen pocos modelos de simulación que se centren en árboles individuales que permitan analizar no solo una fase de desarrollo específica, sino que también derivan decisiones de cosecha económicamente eficientes sin asumir un tipo de raleos específico (Koster & Fuchs, 2022). El Ministerio de Agricultura y Desarrollo Rural (2021), recomienda el empleo de las densidades básicas y normales de la madera en la conversión de unidades volumétricas, dado que puede permitir relacionar especies y volúmenes movilizados con mayor precisión, esto con el propósito de tener en cuenta la singularidad del comportamiento de la madera de cada especie desde sus propiedades físicas.

El estudio de raleo desarrollado por Kuehne et al (2022) para la gestión del pino silvestre (*Pinus sylvestris* L.) en Noruega presenta un sistema de ecuaciones que forman un modelo

de rendimiento y crecimiento a nivel de rodal ajustado a datos experimentales a largo plazo, con y sin los efectos del raleo silvícola. El modelo de crecimiento y rendimiento consta de ecuaciones de componentes para (i) altura dominante, (ii) densidad de tallos (número de tallos por hectárea), (iii) área basal total, (iv) y volumen total de tallos ajustados simultáneamente regresiones aparentemente no relacionadas. El examen del modelo por medio de varias estadísticas de ajuste no indicó ningún sesgo evidente ni una mejora en la precisión de la predicción en comparación con los modelos existentes en general. Una aplicación del modelo desarrollado a nivel de rodal que compara diferentes escenarios de gestión exhibió un comportamiento aceptable a largo plazo.

### 1.3 Índices de competencia

La competencia en los bosques puede definirse como interacciones entre árboles individuales que conducen a una reducción en la supervivencia, crecimiento y regeneración del árbol en cuestión (S. Sun et al., 2019). A medida que el dosel se cierra gradualmente, aumenta la competencia y los individuos grandes suprimen el crecimiento de los individuos más pequeños al interceptar una cantidad de luz disponible desproporcionada al tamaño. Por lo que, la desigualdad de tamaño aumenta con la edad, la calidad del sitio (Barrios-Trilleras et al., 2021), la heterogeneidad ambiental y, para un valor dado de estas variables, una mayor desigualdad de tamaño reduce el crecimiento (H. Sun et al., 2018).

Dado que la competencia entre árboles depende de las especies de árboles, el tamaño del árbol (diámetro, altura, ancho de copa, etc.), el tamaño y la ubicación de los árboles vecinos y, por lo tanto, las condiciones del rodal (Kahriman et al., 2019), el efecto de la competencia en el crecimiento de árboles individuales ha jugado un papel clave en los modelos de árboles individuales, ya que refleja el suministro de recursos de los árboles individuales. Los índices de competencia son formulaciones matemáticas que expresan cuánto se ve afectado cada árbol por sus vecinos. Además, que generalmente se usan como una variable explicativa en los modelos de rendimiento de árboles individuales, dado que esta competencia contribuye significativamente a la determinación de las relaciones de crecimiento (S. Sun et al., 2019).

Según Jansson (2017), la competencia es una preocupación para la reproducción de árboles debido a su potencial para reducir la ganancia genética. La competencia, si no se tiene en cuenta en el modelo analítico, puede potencialmente introducir una fuente de sesgo en la estimación de los parámetros genéticos y la predicción del valor genético. Por lo que, la contribución del índice de competencia en estos modelos es presentar el estado de competencia del árbol en cuestión en relación con los árboles competidores vecinos (Kahriman et al., 2019). Sin embargo, el éxito de un índice de competencia también varía según la especie de árbol, los datos disponibles y, en particular, la estructura del modelo seleccionado (Kahriman et al., 2019). Dado que los índices de competencia se basan en las propiedades del árbol en cuestión y sus vecinos, se consideran importantes para definir el estado competitivo del árbol en cuestión (Richards et al., 2008; S. Sun et al., 2019).

Tabla 1: Índice de competencia independiente de la distancia

NOMBRE DEL ÍNDICE DE COMPETENCIA	EXPRESIÓN MATEMÁTICA
Número de árboles por hectárea (N)	$\sum_{i=1}^n N_i \cdot 10000/S$
Reineke (1933) (SDI)	$10^{(\log N + 1,605 \cdot \log d - 1,605)}$
Wykoff et al. (1982) (BAL)	$\pi/4 \sum_{i=1}^n d_{mayor_i}^2 \cdot 10000/S = BAL_i$
Fracción de cabida cubierta (FCC)	$\pi/4 \sum_{i=1}^n dc_i^2 \cdot 100/S$
Índice de Hart (IH)	$100/(H_o \cdot \sqrt{N})$
Área basal por hectárea (G)	$\pi/4 \sum_{i=1}^n d_i^2 \cdot 10000/S$
Balrel	$BAL_i/G$
Schröder & Gadow (1999) (Balmod)	$(1 - [1 - BAL_i/G]) / IH$

**Leyenda:** n: número de árboles por parcela, S: superficie de la parcela (m<sup>2</sup>), d<sub>i</sub>: diámetro normal del árbol seleccionado (cm), H<sub>0</sub>: altura dominante (m), dc<sub>i</sub>: diámetro de copa, en proyección horizontal, del árbol seleccionado (m), d<sub>mayori</sub>: diámetro normal de los árboles mayores que el árbol seleccionado (cm), G: área basal de la parcela (m<sup>2</sup>).  
Modificado de Kahrman (2019)

Según la división clásica de Munro (1974), los índices de competencia se pueden dividir en dos grupos: **Índices independientes de la distancia**, los cuales no requieren el conocimiento de las coordenadas de los árboles y la distancia entre los árboles, ya que son funciones de los parámetros generales a nivel del rodal o las dimensiones iniciales del árbol en cuestión (Kahrman et al., 2019). Ver tabla 1 basada en (Álvarez-Taboada, Barrio-Anta, Gorgoso-Varela, et al., 2003; Crecente Campo et al., 2007). **Índices dependientes de la distancia**, los cuales se calculan como las funciones de las dimensiones iniciales del árbol en cuestión y la distancia y las dimensiones de los árboles competidores vecinos (Kahrman et al., 2019). Ver tabla 2 basada en (Álvarez-Taboada, Barrio-Anta, Gorgoso-Varela, et al., 2003; Crecente Campo et al., 2007).

Tabla 2: Índices de competencia dependientes de la distancia.

NOMBRE DEL ÍNDICE DE COMPETENCIA	EXPRESIÓN MATEMÁTICA
Staebler (1951)	$\sum_{i \neq j} L_{i,j}$
Hegyí (1974)	$\sum_{i \neq j} \frac{d_j}{(d_i \cdot Dist_{i,j})}$
Martín & ek (1984)	$\sum_{i \neq j} \left( \frac{d_j}{d_i} \right) \cdot \exp \left( \frac{(16 \cdot Dist_{i,j})}{(d_i + d_j)} \right)$
Daniels et al. (1986)	$\frac{(d_i^2 \cdot n)}{(\sum_{i \neq j} d_j^2)}$
Pukkala y Kolström (1987)	$\sum_{i \neq j} \frac{h_i}{(h_j \cdot Dist_{i,j})}$
Biging & Dobbertin (1992)	$\sum_{i \neq j} \frac{CC_j}{(CC_i(Dist_{i,j} + 1))}$

**Leyenda:**  $L_{ij}$ : longitud del segmento que une los centros del árbol seleccionado y de su competidor, incluida en el área de solapamiento de sus zonas de influencia (m)),  $d_j$ : diámetro normal del árbol competidor (cm),  $Dist_{ij}$ : distancia en proyección horizontal entre el árbol seleccionado y el árbol competidor (m),  $CC_i$ : superficie de copa en proyección horizontal del árbol seleccionado ( $m^2$ ),  $CC_j$ : superficie de copa en proyección horizontal del árbol competidor ( $m^2$ ),  $n$ : número de árboles competidores,  $h_i$ : altura total del árbol seleccionado (m),  $h_j$ : altura total del árbol competidor (m). Modificado de Kahrman (2019).

Como se plantea en la metodología, la competencia, representada en número de árboles competidores y el cálculo de los índices de competencia, son la base para que la Red Neuronal Artificial obtenga la sensibilidad necesaria para modelar las intervenciones de densidad mediante los raleos. Este proceso de modificación abrupta de la densidad altera el comportamiento en el crecimiento de los árboles, lo que para el modelo representan dinámicas no lineales. Los modelos alométricos basados en funciones de regresión estadísticas no alcanzan a modelar por sí mismas, los cambios abruptos en la dinámica del rodal.

## 1.4 Diagramas de Manejo de Densidad

Los diagramas para el manejo de la densidad (DMD) son una de las principales herramientas para la planeación y la realización del manejo forestal que brindan apoyo para el proceso de toma de decisiones en el manejo de la densidad y prescribir raleos como tratamientos silvícolas intermedios (Tamarit-Urias et al., 2019). Estudiar la densidad y su vinculación con el desarrollo del rodal futuro es posible mediante el análisis de las relaciones de tamaño-densidad. Estas relaciones son básicas para determinar los índices de densidad del rodal (Cárcamo et al., 2011).

En este trabajo se revisan dos índices que se utilizan como indicadores para controlar y manejar la densidad dentro de una plantación: Uno es el Índice de Densidad de Rodal (IDR), y el otro es el Índice de Espaciamiento Relativo o Índice de Hart-Beckin. A través de los Diagramas de Manejo de Densidad, como herramientas importantes para la toma de decisiones, se construye el programa de planificación de raleos, para nuestro caso, de la especie *Gmelina arborea* Roxb., en el Departamento del Tolima.

### 1.4.1 Índice de Densidad del Rodal (IDR) de Reineke

Este índice mide la relación entre el número de árboles por unidad de área con su diámetro medio cuadrático sin tener en cuenta su edad, ni calidad de sitio; se fundamenta en la regla de autoraleo, que describe el comportamiento de la mortalidad cuando por la competencia entre los árboles se alcanza su máxima densidad (Arias Aguilar, 2004). Desde que Reineke (1933) propuso un índice de densidad de rodales (IDR) para cuantificar la densidad de población en rodales de edad uniforme, se ha utilizado ampliamente como medida de competencia y ocupación del sitio (S. Sun et al., 2019).

Este índice hace uso de las variables: número de árboles por hectárea  $N$ , diámetro medio cuadrático de la plantación  $Dg$  y una constante “ $b$ ” definida en primera instancia por Reineke (1933) con un valor de  $-1,605$  para varias especies. De este modo el índice corresponde al número de árboles por hectárea que un rodal específico podría alcanzar si su diámetro medio cuadrático fuera de 25 cm, expresado en la siguiente ecuación (Arias Aguilar, 2004):

$$\mathbf{IDR} = N * \left(\frac{25}{Dg}\right)^b \quad (1.1)$$

A partir de las parcelas con máxima densidad, y aplicando a este grupo de parcelas los valores  $Y = \text{Log}_{10} N$  y  $X = \text{Log}_{10} Dg$  se obtiene el modelo lineal  $Y = a + b(X)$ . Se puede obtener el valor máximo del índice de densidad de rodal ( $\text{IDR}_{\text{max}}$ ). Este indicador permite estudiar diferentes rodales (o especies) y compararlos desde un punto de vista eco-fisiológico.

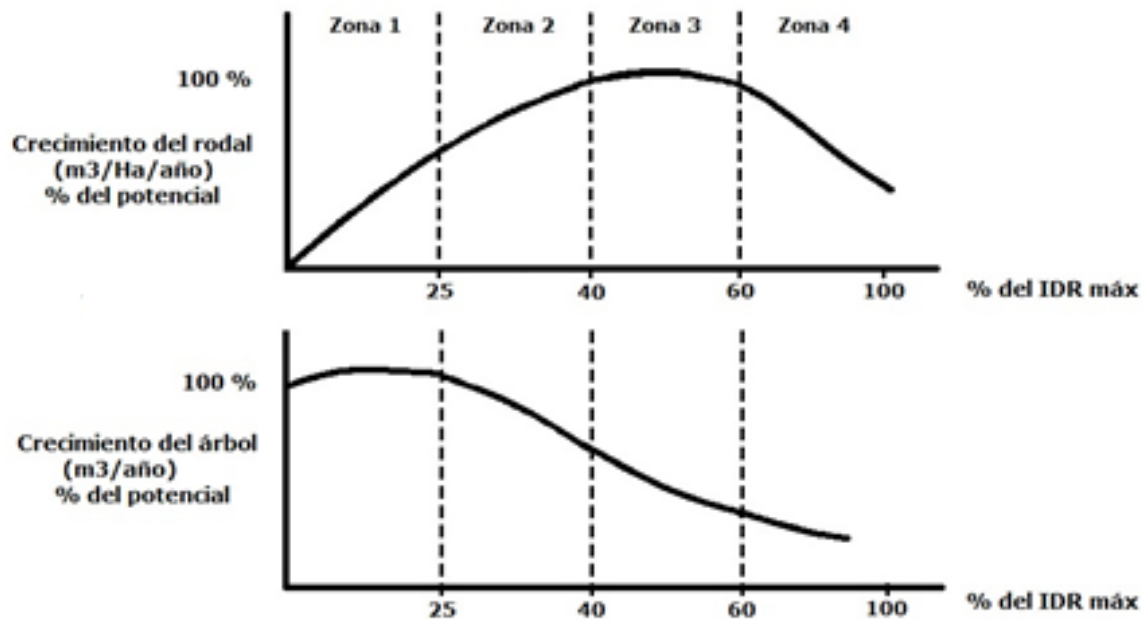


Figura 6: Crecimiento anual del rodal (arriba) y de árboles individual (Inferior) en relación con el valor del crecimiento.

Fuente: Langsaeter (1941), citado por Long (1985).

El  $IDR_{\max}$  corresponde a una relación teórica que describe la trayectoria seguida por el número de individuos de aquellos rodales que se encuentran en completa ocupación del sitio, es decir, el nivel máximo de competencia, y por ende es frecuentemente utilizado como indicador del límite superior de carga del rodal. La siguiente expresión se utilizó para determinar el  $IDR_{\max}$  (Gezan et al., 2007):

$$IDR_{\max} = 10^{a_{\max}} * 25^b \quad (1.2)$$

donde  $a_{\max} = a + (1,96 * \text{Root MSE})$

Las zonas de densidad establecidas en el estudio toman como referencia lo propuesto por Ortiz (1986), Arias y Campos (1987) y Arias (Arias Aguilar, 2002); quienes reconocen cuatro zonas de densidad (Figura 6).

- Zona 1 (zona de subutilización del sitio) la densidad del rodal es baja y los árboles crecen en forma aislada. El crecimiento por árbol es máximo mientras que el

crecimiento/Ha del rodal es mínimo, pero este se incrementa a medida que se aumenta el número de árboles/Ha.

- Zona 2 (zona de transición) el crecimiento individual de los árboles comienza a disminuir y el crecimiento/Ha del rodal aumenta debido al incremento de la densidad. Si se desea maximizar el crecimiento/árbol para producir madera para aserrar se debe evitar que la densidad del rodal supere el límite superior de esta zona; y si por el contrario se quiere maximizar el crecimiento/Ha se debe evitar que después de un raleo, la densidad sea inferior al límite superior de esta zona.
- Zona 3 (zona de máximo crecimiento/Ha) el crecimiento/árbol tiende a ser mínimo a medida que aumenta la densidad, pero el crecimiento/Ha alcanza su máximo. Si el objetivo de la plantación es producir madera para postes, pulpa o leña se debe mantener la densidad del rodal dentro de la zona.
- Zona 4 (zona de autoraleo) es la zona donde el límite superior está dado por el  $IDR_{max}$  de la especie; hacia el límite superior de esta zona los árboles empiezan a morir por exceso de competencia (autoraleo), el crecimiento/Ha y el crecimiento/árbol es mínimo, por lo tanto, la plantación no se debe ubicar dentro de esta zona.

Una vez establecido el  $IDR_{max}$  y definidas las zonas de densidad, utilizando la metodología citada en (Arias Aguilar, 2004), se construye una tabla que describe el programa de raleos para la especie Melina en el área de estudio, con el objetivo de producir madera para aserrío.

### 1.4.2 Índice de Espaciamento Relativo

El índice de Hart-Becking, conocido también como índice de espaciamento relativo o factor de espaciamento en forma porcentual (%IH), es un indicador de la densidad para rodales regulares que se calcula a partir de un número de árboles por hectárea (N) y su altura dominante ( $H_0$ ). Este índice es útil para caracterizar la densidad de una masa por ser independiente de la calidad de estación y de la edad (excepto para rodales muy jóvenes). La altura dominante, incluida en su formulación, es el mejor índice para establecer los intervalos de claras para una determinada especie desde un punto de vista biológico,

según citan Escobedo Soto (2014) y Díaz Gómez y Pava Gantivar (2015), de la siguiente manera:

$$IH\% = k \frac{100}{\sqrt{N}H_0} 100 \quad (1.3)$$

Donde la constante K es igual a 1 si se asume una distribución de los árboles en marco real o malla cuadrada (típica de plantaciones), o igual a (4/3) 0,25 si se asume una distribución al tresbolillo o triangular (aplicada habitualmente a rodales naturales) (Diéguez-Aranda et al., 2009). Quiere decir, que a medida que aumenta el número de árboles por hectárea para una misma altura dominante, se incrementa la densidad del rodal, pero disminuye el valor de IH (Gadow et al., 2007).

El índice de Hart-Becking ofrece variadas ventajas en la determinación de la necesidad y el peso de los raleos, por su fácil interpretación, amplio uso, permite la caracterización de la densidad al ser independiente de la calidad de sitio y de la edad (excepto para rodales muy jóvenes), y también porque la altura dominante (incluida en su formulación) es el mejor índice para establecer los intervalos de raleo para una determinada especie, desde un punto de vista biológico (Diéguez-Aranda et al., 2009).

En la Figura 7, se muestra un diagrama de manejo de densidad (DMD) en el que se aprecian las distintas líneas de valores constantes (o isolíneas) de volumen del rodal, diámetro medio cuadrático e índice de Hart-Becking. En el eje de ordenadas se representa el número de pies por hectárea (en escala logarítmica) y en el eje de abscisas la altura dominante según el criterio derivado de Assmann (altura media de los 100 pies más gruesos por hectárea) (Diéguez-Aranda et al., 2009).




Figura 7: Aspecto de un DMD con líneas de valores constantes (o isolíneas) Incluye Isolíneas de volumen del rodal, diámetro medio cuadrático e índice de Hart-Becking. Fuente: Diéguez-Aranda et al. (2009)

## 1.5 Técnicas de la Inteligencia Computacional

Las RNA son técnicas computacionales que imitan el sistema nervioso del cerebro humano para generar un conjunto de unidades de procesamiento paralelas. Al igual que otras técnicas de aprendizaje automático, tienen la capacidad de aprender y modelar relaciones no lineales y complejas. Las RNA son flexibles para resolver problemas complejos con múltiples variables que interactúan, lo cual es realmente importante para modelar las relaciones no lineales y complejas que se generan al momento de las intervenciones de raleos (Bayat et al., 2019).

Las RNA han sido utilizadas para optimizar índices de competencia (Richards et al., 2008); para predecir el crecimiento de los árboles individuales (Ashraf et al., 2015) y a nivel de bosque (Bayat et al., 2019) teniendo en cuenta las condiciones climáticas actuales y proyectadas, para predecir el crecimiento de los árboles y la biomasa (Martins Silva et al., 2019). El desempeño de la RNA ha sido comparado con el de los modelos mixtos, siendo

los modelos de RNA más precisos a medida que aumenta el número de mediciones (Skudnik & Jevšenak, 2022).

### 1.5.1 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) son una de las principales técnicas de aprendizaje automático, ampliamente utilizadas para desarrollar modelos de regresión y predicción.

Las RNA están inspiradas en las neurona biológicas (sistemas bioinspirados). Una neurona es una célula que, a través de reacciones bioquímicas, tiene la capacidad de recibir, procesar y transmitir información. Por tanto, la unidad básica a modelar es la neurona. El proceso de interconexión entre neuronas se denomina sinapsis y su representación en el modelo son valores ponderados  $w_i$  que se denominan pesos sinápticos. Un modelo con varias capas ocultas de neuronas se denomina "perceptrón multicapa". El perceptrón multicapa, se conoce como el algoritmo de red neuronal común que se usa ampliamente en diferentes áreas, como la botánica, la detección remota, las ciencias ambientales y la ingeniería. Al igual que otros algoritmos de redes neuronales, se basa en conjuntos de neuronas distribuidas en capas en las que cada una tiene su propio peso específico que conecta con cada una de las neuronas de la capa siguiente (Yoosefzadeh-Najafabadi et al., 2021).

La complejidad de los modelos crece a medida que aumenta el número de neuronas o capas. Así, un modelo con  $m$  neuronas en su primera capa y  $n$  neuronas en la siguiente, tendrá un número de pesos equivalente a  $m \times n$ , si sus capas están completamente conectadas. La arquitectura de la red es decisiva para la tarea que le corresponde, por lo que mientras hace unos años los modelos solo tenían unas pocas capas de neuronas, los modelos más recientes pueden tener decenas o incluso cientos. La aparición de RNA con memoria especializadas en manejo de series de tiempo (Redes Neuronales Recurrentes), Redes neuronales que incluyen filtros que relacionan características en imágenes para detección de objetos (Redes Neuronales Convolucionales). Las nuevas características de estos modelos de Red neuronal dio origen a la expresión 'Deep Learning' (aprendizaje

profundo), en referencia a la profundidad de los modelos utilizados, su estructura jerárquica y su alta dimensionalidad (Fuchs, 2018).

Una de las tareas a resolver con la ayuda de las Redes Neuronales Artificiales Multicapa con conexiones hacia adelante (Figura 4), es la generalización del comportamiento de un Sistema (proceso), obtenido a partir del entrenamiento de la Red Neuronal, con los datos de entrada y salida, es decir, al igual que una función de regresión, permite modelar la tendencia del sistema.

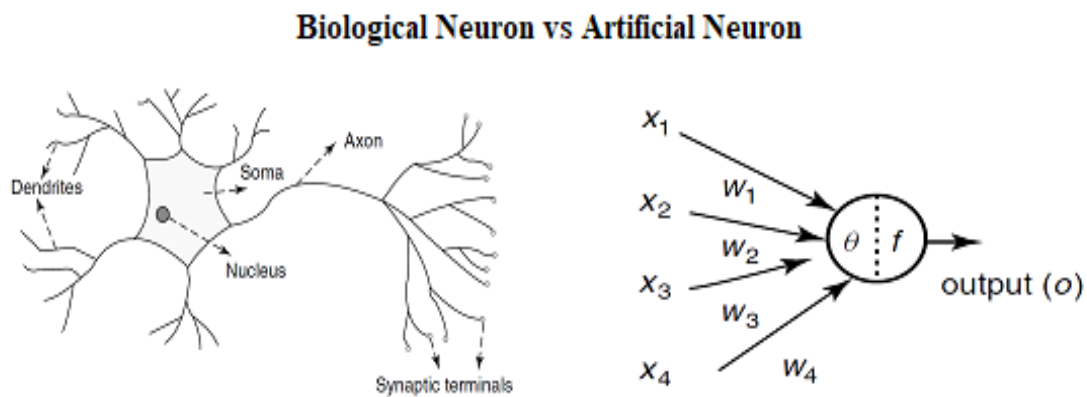


Figura 8: Representación de una neurona biológica vs una neurona artificial

La red viene distribuida en capas de neuronas: una capa de entrada, una capa de salida y una o más capas ocultas. Cada neurona de una capa está interconectada con todas las neuronas de la capa siguiente, como se muestra en la Figura 20. Una neurona  $x$  recibe  $n$  entradas y devuelve un valor de salida  $a(x)$  (S. H. Chen et al., 2008)

$$a(x) = g\left(\sum_{i=0}^n w_i x_i\right) \quad (1.4)$$

Donde ( $w_0, \dots, w_n$ ) son los pesos de entrada y  $g$  es una función no lineal de activación que, usualmente, puede ser una función paso (límite) o una función sigmoidea (Figura 20).

La figura 8 ilustra la representación de una neurona biológica y la representación de una neurona artificial y la figura 9 representa la Red Neuronal Artificial Multicapa también llamada Perceptrón multicapa (Abraham, 2005).




Figura 9: Red Neuronal Artificial Multicapa

Fuente: Modificado de: Chen et al. (2008)

La salida de la función paso es  $a = 1$  si  $x \geq \theta$ , ó  $0$  si  $x \leq \theta$ , siendo  $\theta$  un valor de umbral (threshold). Ecuación 1.5:

$$g(x) = \begin{cases} 0, & x < \theta \\ 1, & x \geq \theta \end{cases} \quad (1.5)$$

La función sigmoidea, usualmente es asintótica en 0 y 1 y antisimétrica en el intervalo (0, 0.5) (Chen et achl., 2008). Ecuación 1.6:

$$g(x) = \frac{1}{1 + e^{-\beta x}}, \beta > 0 \quad (1.6)$$




Figura 10: Representación gráfica de las funciones de activación.

Izquierda: función de activación sigmoidea. Derecha: función de activación ReLU.  
Fuente: Fuchs (2018)

Las Redes Neuronales Artificiales se han utilizado en múltiples estudios con diferentes objetivos, entre ellos se pueden encontrar:

Richards et al. (2008), quienes realizaron un modelo con el fin de optimizar tres índices de competencia: Lorimer, Heygi y Pukkala-Kolstrom, para predecir el crecimiento radial anual del pino silvestre. Para esto, usaron una red neuronal que predecía el ancho del anillo de crecimiento del árbol, la cual se optimizó con la técnica del Recocido Simulado (Simulated Annealing), utilizado en el cálculo de los índices de competencia de árboles individuales. Las entradas del modelo incluyeron el DAP del árbol (diámetro a la altura del pecho) y variables ambientales (exposición, humedad del suelo) y topográficas (aspecto, altitud).

Ashraf et al. (2015), desarrollaron un modelo de crecimiento y rendimiento forestal que se puede utilizar para predecir el crecimiento de árboles individuales en las condiciones climáticas actuales y futuras proyectadas, haciendo uso de redes neuronales. Los parámetros tenidos en cuenta para el modelo incluyeron la altura, el DAP del árbol, la temperatura, el área basal y la edad del rodal; y atributos como la especie y el clima. A diferencia nuestra, en este trabajo no se utiliza la competencia como variable de árbol individual.

Bayat et al. (2019), quienes diseñaron un modelo mixto empleando una red neuronal para predecir la supervivencia y mortalidad de árboles en un bosque de hayas orientales en el norte de Irán, utilizando datos a largo plazo y variables tales como la altura, el DAP, el área basal y ambientales como la radiación solar.

Martins Silva et al. (2019), diseñaron un modelo mixto con el fin de predecir el volumen y la biomasa de árboles individuales de la sabana brasileña, haciendo uso de técnicas de inteligencia artificial que son capaces de mapear patrones de entrada y descubrir patrones ocultos en heterogéneos no lineales de alta dimensión para minimizar errores en las estimaciones. Se utilizaron variables numéricas (diámetro a la altura de 1,30 m del suelo, altura total, volumen y biomasa) y variables categóricas (especies) para el entrenamiento y ajuste de técnicas de IA y modelos mixtos, respectivamente.

Skudnik y Jevšenak (Skudnik & Jevšenak, 2022), comparan el uso de modelos no lineales mixtos y modelos de redes neuronales para predecir la altura de árboles para una variedad de diferentes especies de árboles específicas de Europa central. Teniendo en cuenta variables como el DAP y el área basal. Al inicio, los modelos de efectos mixtos proporcionaron las predicciones de altura de árbol más precisas a nivel de parcela, especialmente para especies de árboles con un número menor de medidas de altura de árbol. Cuando las parcelas se agruparon y se aumentaron el número de observaciones por categoría, las predicciones de RNA mejoraron y se volvieron más precisas que las proporcionadas por los modelos de efectos mixtos.

En este estudio se utilizaron las Reden Neuronales del tipo Perceptrón Multicapa (MLP), en razón a que tienen un gran potencial para estudios de predicción y aproximación de funciones (Görgens et al., 2015; Martins Silva et al., 2019; Nunes & Görgens, 2016; Reis et al., 2018; Vieira et al., 2018). Están compuestos por una capa de entrada, donde se presentan las variables a la red; capas intermedias u ocultas, donde se realiza el procesamiento; y una capa de salida, donde se presenta el resultado. La capa intermedia es responsable de identificar los patrones no lineales de los datos mediante el uso de funciones de activación.

## 1.5.2 Red de Autómatas Celulares

Un autómata celular (AC) es un modelo matemático para un sistema dinámico, compuesto por un conjunto de celdas o células que adquieren distintos estados o valores. Estos estados son alterados de un instante a otro en unidades de tiempo discreto, es decir, que se puede cuantificar con valores enteros a intervalos regulares. De esta manera este conjunto de células logran una evolución según una determinada expresión matemática, que es sensible a los estados de las células vecinas, la cual se le conoce como regla de transición local (Reyes Gómez, 2011).

Según Reyes Gómez (2011), los elementos básicos de un Autómata Celular son:

- **Arreglo Regular.** Ya sea un plano de 2 dimensiones o un espacio n-dimensional, este es el espacio de evoluciones, y cada división homogénea de arreglo es llamada célula.
- **Conjunto de Estados.** Es finito y cada elemento o célula del arreglo toma un valor de este conjunto de estados. También se denomina alfabeto. Puede ser expresado en valores o colores.
- **Configuración Inicial.** Consiste en asignar un estado a cada una de las células del espacio de evolución inicial del sistema
- **Vecindades.** Define el conjunto contiguo de células y posición relativa respecto a cada una de ellas. A cada vecindad diferente corresponde un elemento del conjunto de estados
- **Función Local.** Es la regla de evolución que determina el comportamiento del AC. Se conforma de una célula central y sus vecindades. Define como debe cambiar de estado cada célula dependiendo de los estados anteriores de sus vecindades. Puede ser una expresión algebraica o un grupo de ecuaciones.

Según Lett (1999), una red de autómatas celulares puede ser definida por su estructura y características funcionales:

Las características estructurales consisten en la topología de red, la definición de vecindad y las condiciones de frontera de la red. La topología de red se define por su estructura (sistemas de uno, dos o tres dimensiones), su forma (celdas cuadradas, hexagonales o triangulares) y el número de sus celdas (Figura 7). El vecindario define el conjunto de

celdas que interactúan con una celda determinada: vecinos con celdas adyacentes, o vecinos con celdas no adyacentes (la interacción entre una celda determinada y una celda en su vecindario puede depender de las posiciones relativas de las celdas, por ejemplo, la distancia entre ellas). Las condiciones de contorno se definen para garantizar que las celdas de límite también tengan vecinos.

Las características funcionales están dadas por una lista de estados de las celdas, la configuración inicial de la red y las reglas de transición. Muchos autómatas simples solo tienen dos estados que a menudo representan la presencia o ausencia de un fenómeno dado (por ejemplo, la célula está "muerta" o "viva"). La configuración inicial de la red inicializa el sistema y, en cada paso de tiempo, las reglas de transición determinan la transición potencial de un autómata de un estado a otro. Se pueden usar reglas de transición deterministas o estocásticas.




Figura 11: Representación gráfica de la característica estructural de la red de autómatas celulares bidimensional (2D).

Fuente: Lett et al. (1999)

Los autómatas celulares tienen la capacidad de representar comportamientos complejos a partir de una dinámica sencilla. Estos son sistemas dinámicos, discretos en el espacio, tiempo y estado y con interacciones locales constantes entre sí. Debido a esto, desde su origen se les ha utilizado como elementos de la computación para la modelación de fenómenos biológicos y físicos. En silvicultura, han sido utilizados para resolver problemas de planificación forestal espacial, en la planificación del uso de la tierra y para simular la propagación de plagas forestales y enfermedades. Recientemente, también se utilizaron con éxito para la delimitación de rodales (Jia et al., 2020).

Más precisamente, una red de autómatas celulares puede definirse por sus características estructurales y funcionales. Las características estructurales consisten en la topología de la red, la definición de vecindad y las condiciones de contorno de la red. La topología de la red se define por su estructura (sistemas de una, dos o tres dimensiones), su forma (celdas cuadradas, hexagonales o triangulares) y el número de sus celdas. Vecindad define el conjunto de celdas que interactúan con una celda dada: vecindad con celdas adyacentes, o vecindad con celdas no adyacentes (la interacción entre una celda dada y una celda en su vecindad puede depender sobre las posiciones relativas de las celdas, por ejemplo, la distancia entre ellas). Las condiciones de frontera se definen para asegurar que las celdas de frontera también tengan vecinas. Las características funcionales consisten en la lista de estados de celda, la configuración inicial de la red y las reglas de transición. Muchos autómatas simples solo tienen dos estados que a menudo representan la presencia o ausencia de un fenómeno dado (por ejemplo, la celda está "muerta" o "viva"). La configuración inicial de la red inicializa el sistema y, en cada paso de tiempo, las reglas de transición determinan la transición potencial de un autómata de un estado a otro (Lett et al., 1999).

### 1.5.3 Algoritmos Genéticos

El Británico Charles Darwin, en su publicación *El origen de las especies por selección natural*, sentó las bases de la Teoría de la Evolución. Haciendo un símil con esta teoría, la primera idea surgió en 1967 por J. D. Bagley quien realizó su tesis "El funcionamiento de los sistemas adaptables empleando algoritmos genéticos y correlativos", la cual influyó a J. H. Holland, para que siguiera el desarrollo de este método algorítmico y fuera considerado como el pionero de los Algoritmos Genéticos (AG) (Ponce Cruz, 2010).

Los AG pueden concebirse como métodos de búsqueda y optimización, que no intentan modelar la evolución biológica, sino que, a partir de los principios de la evolución, se encuentren estrategias de optimización (Ponce Cruz, 2010).

El concepto se basa en primer lugar, en modelar las características de una solución de un problema de la vida real (que correspondería al fenotipo de un individuo) mediante una cadena a manera de un cromosoma (genotipo), en donde cada característica modelada corresponde a una subcadena o gen y cuyos valores numéricos corresponden a una solución al problema modelado.

A partir de la generación aleatoria de una población inicial de individuos  $G(0)$ , a quienes se consideran como los padres, se siguen las reglas básicas de la Teoría de la Evolución: durante el curso de la evolución, los genes con evolución lenta fueron reemplazados por genes con mejor estrategia evolutiva. Por lo tanto, en la fauna y la flora modernas, se esperan estrategias altamente eficientes (Ponce Cruz, 2010), así mismo, la idea de los AG es optimizar (hallar el máximo o mínimo) con base en una función objetivo evaluada a partir de los valores presentes en la cadena (cromosoma), utilizando los principios de la selección natural sobre los parámetros de la función.

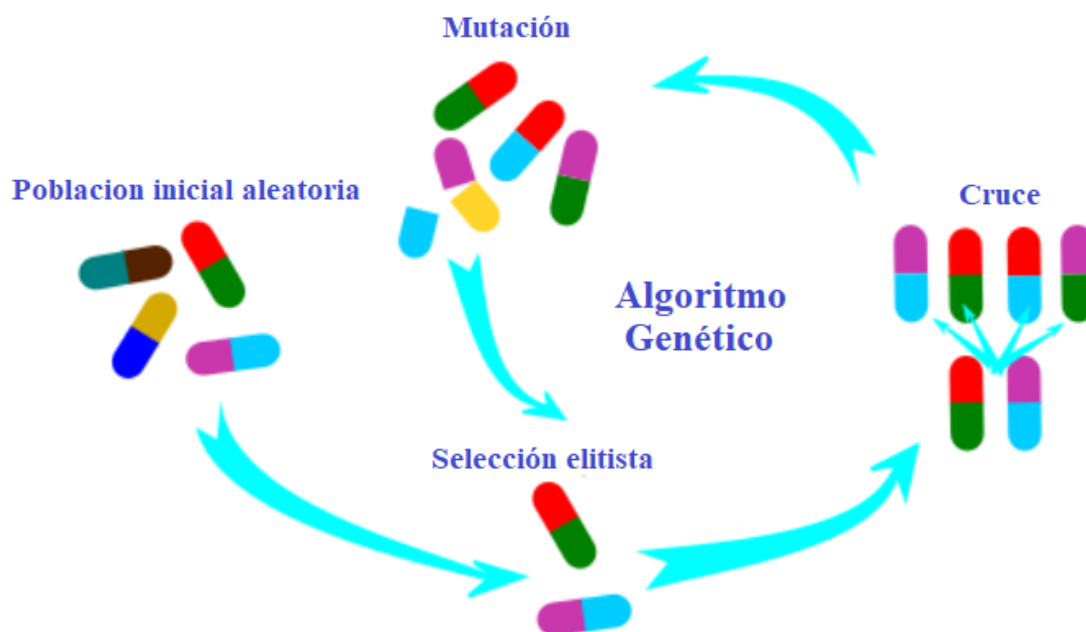


Figura 12: Diagrama de flujo del algoritmo genético como algoritmo de optimización

Fuente: <https://pastmike.com/what-is-a-genetic-algorithm/>

El algoritmo evoluciona a partir de la población inicial  $G(0)$ , a través de las soluciones de ajuste en una población  $G(t)$  que sobrevive, mediante la selección y la reproducción, pasan sus rasgos a su descendencia  $G(t + 1)$  en donde las soluciones más pobres son reemplazadas, hasta encontrar la óptima, o la más cercana a la óptima, solución que satisface al problema. La selección de los individuos se realiza por el método de la ruleta (selecciona al azar de un padre a partir de una probabilidad calculada) y/o por muestreo

determinístico. La reproducción se realiza por cruce genético y mutación sobre la cadena (cromosoma). En el cruce genético se intercambian segmentos cromosómicos de dos padres y, en la mutación, se cambia aleatoriamente parte del cromosoma de uno de los padres como forma de introducir nuevo material genético, sin el cual, la evolución se retarda o puede detenerse. Las poblaciones sucesivas se conocen como generaciones (S. H. Chen et al., 2008).

Dentro de la metodología propuesta, con el uso de algoritmos genético, se obtendrá una aproximación a la solución óptima que busca maximizar el volumen de madera al momento del aprovechamiento fina

Los Algoritmos Genéticos (AGs) son métodos adaptativos que pueden usarse para resolver problemas de búsqueda y optimización. Están basados en el proceso genético de los organismos vivos. A lo largo de las generaciones, las poblaciones evolucionan en la naturaleza de acorde con los principios de la selección natural y la supervivencia de los más fuertes, postulados por Darwin en el año 1859 en sus estudios de selección natural. Por imitación de este proceso, los Algoritmos Genéticos son capaces de ir creando soluciones para problemas del mundo real. Son una técnica de búsqueda basada en la población, que ofrece un método ideal para encontrar un conjunto de regímenes igualmente eficientes en la región óptima del problema modelado (Chikumbo & Nicholas, 2011).

En la literatura revisada, los algoritmos genéticos han sido utilizados para optimizar la producción de arroz (F. Chen et al., 2019); de soja (Yoosefzadeh-Najafabadi et al., 2021); y cultivos hortícolas (West, 2019); e incluso de granjas lecheras (Breen et al., 2019; Hassani et al., 2019); además de que se han utilizado para optimizar misiones agrícolas de forma adecuada haciendo uso de recursos limitados de forma razonable y con una intervención humana mínima (Zhai et al., 2018). La aplicación de algoritmos genéticos en silvicultura, y específicamente en los regímenes de raleo (Chikumbo & Nicholas, 2011), donde se consideran objetivos tanto el valor como el volumen de producción. Los principios básicos de los Algoritmos Genéticos fueron establecidos por John H. Holland (1992).

Para efectos de maximización del volumen final de la cosecha, las estrategias de la intervención silvicultural en la densidad del rodal (tiempos e intensidad de raleo), serán determinadas por un Algoritmo Genético. Para la evaluación de la función objetivo, por

cada individuo de la población, se simula el crecimiento de un rodal de una hectárea por año, calculando el volumen de madera que se recoge en cada raleo y la cosecha final.

En razón a que se está maximizando el volumen de la madera, se adjunta una simulación de captura de carbono, a partir de los estudios que se tienen al respecto (Patiño et al., 2018; Rodríguez Santos, 2013), el cual sirve como un insumo para la negociación de bonos de carbono e incentivo a la inversión.

En las operaciones de raleo, los administradores forestales evalúan periódicamente los beneficios y costos incrementales de cada posible decisión de aprovechamiento. Para contribuir a la comprensión de estas decisiones económico-silvícolas, la teoría de la inversión proporciona un marco en el que analizar soluciones económicamente eficientes (Koster & Fuchs, 2022). Sin embargo, esto no se encuentra dentro del alcance de esta investigación, por lo cual se propone como tema de investigación futuro.

Como conclusión del capítulo podemos decir que los modelos alométricos de crecimiento y rendimiento de rodal, implementados a través de técnicas de regresión, revisados en la literatura, presentan alto grado de complejidad que, terminan haciéndolos poco atractivos al momento de ser utilizados con propósitos de manejo de las plantaciones. Además, en la actualidad, la generalidad de modelos implementados para el sector forestal, no incluyen las herramientas computacionales de la Inteligencia Computacional.

## 2 PROBLEMA DE INVESTIGACIÓN:

El ritmo de la deforestación de los bosques naturales en Colombia viene en aumento, mientras que el establecimiento de nuevas plantaciones forestales se ha estancado, ante la baja rentabilidad económica del sector. Para el año 2020, en nuestro país, el 65% de la madera para satisfacer las necesidades de la industria nacional del muebles, construcción, papel y combustible, provenían de los bosques naturales (DANE,2021).

Se hace necesario incentivar el establecimiento de nuevas plantaciones forestales, bajo programas de mejoramiento, plantación optimizada de las especies deseadas y aplicación de tratamientos silvícolas, que suministren un mayor porcentaje de la madera requerida por la industria (Dash et al., 2019), (Thiffault et al., 2021).

Amaya Arias (2020), señala que la investigación científica en los ecosistemas boscosos tropicales es indispensable para avanzar hacia el desarrollo sostenible del sector forestal colombiano. En este sentido, el Plan Nacional de Desarrollo Forestal establece que el Estado “estimulará y promoverá la investigación científica y tecnológica y el conocimiento tradicional como elementos fundamentales para el manejo sostenible y conservación de los ecosistemas forestales” (Amaya Arias, 2020).

Se necesita entonces construir herramientas tecnológicas que permitan reducir la incertidumbre en la toma de decisiones de los procesos de producción de las plantaciones forestales.

## 2.1 Proceso de producción

Para introducirnos en el problema de esta investigación se hace necesario una breve explicación del Proceso de producción de madera en una plantación forestal:

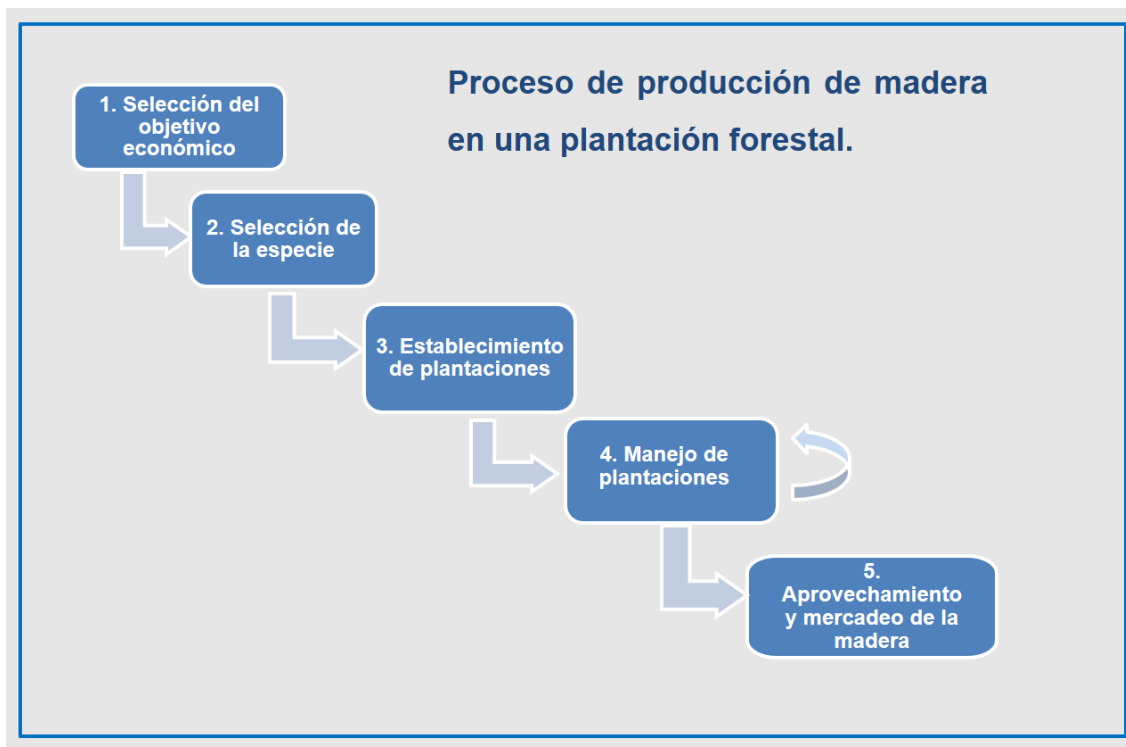


Figura 13: Proceso de producción de una plantación forestal

Fuente: Autor

### 2.1.1 Primera etapa: Selección del objetivo económico.

De acuerdo con el propósito de producción podemos identificar los siguientes objetivos económicos:

- Maximizar la rentabilidad de la **producción de madera** maximizando el **volumen de madera** producido.
- Maximizar la rentabilidad de la **producción de madera combinada** con los ingresos por venta de **bonos de carbono** asociados a la biomasa acumulada en el ciclo de producción maderera.
- Maximizar la rentabilidad de la **biomasa para pulpa de papel**.

- Maximizar la rentabilidad de los **bonos de carbono** en **cultivo permanentes**.

### 2.1.2 Segunda etapa: Selección de la especie forestal.

En la actualidad, se han identificado varias especies promisorias, entre las que se destaca la *Gmelina arborea* Roxb, siendo ésta la octava especie con mayor aporte de volumen, específicamente con 57887,88 m<sup>3</sup> (Ministerio de Agricultura y Desarrollo Rural, 2021). La especie presenta dureza en la madera con una rápida tasa de crecimiento, facilidad y bajo costo de establecimiento, idónea para la industria de pulpa, papel y también para productos de madera maciza, cuyas propiedades materiales son de permanente estudio. Es una especie que se adapta muy bien en los bosques secos tropicales y puede desarrollarse extensivamente donde nunca ha existido antes (Iwuoha et al., 2021). El estudio y modelado del comportamiento de especies promisorias, permitirá a las diferentes comunidades, realizar un aprovechamiento sostenible. Con este propósito, la especie seleccionada para este estudio es la especie *Gmelina arborea* Roxb., aprovechado la información que se tiene de las parcelas que hacen parte de un estudio de monitoreo sobre el crecimiento y rendimiento de la especie en el Departamento del Tolima: “Desarrollo de un modelo de planificación para las plantaciones de *Tectona grandis*, *Gmelina arborea*, *Pinus patula*, *Pinus oocarpa* y *Eucalyptus grandis*, como apoyo a la consolidación del proyecto de reforestación comercial del Tolima”–3485. El cual desarrollan: La Corporación Nacional de Investigación y Fomento Forestal- CONIF en alianza con la Gobernación del Tolima, CORCUENCAS y la Universidad del Tolima. Proyecto cofinanciado por Ministerio de Agricultura y Desarrollo Rural

*Gmelina arborea* es una de las especies exóticas de madera dura con una tasa de crecimiento rápido que puede crecer en una amplia gama de suelos y condiciones climáticas (Adeleke et al., 2019; Chigbundu Chijioke et al., 2022). La *Gmelina arborea* Roxb., es una especie forestal perteneciente a la familia Lamiaceae que alcanza los 35 m de altura y presentar más de 3 m de diámetro en rodales naturales de las regiones tropicales, es capaz de alcanzar un diámetro medio a la altura del pecho (DAP) de entre 60 y 80 cm en tan solo 20 años (Iwuoha et al., 2021).

Es una de las especies más importantes para la plantación en áreas tropicales y puede desarrollarse extensivamente donde nunca ha existido antes. *Gmelina* no es una especie amenazada y tiene una resistencia al fuego comparativamente buena (Iwuoha et al., 2021). Debido a su rápida tasa de crecimiento, facilidad y bajo costo de establecimiento, es de gran interés para su aprovechamiento, siendo idónea para pulpa, papel y también para productos de madera maciza, por lo que se ha descrito como una especie arbórea muy prometedora ofreciendo amplias posibilidades para el desarrollo de reforestaciones industriales en Colombia (Obregón Sánchez, 2006).



Figura 14: Plantación de *Gmelina arborea* Roxb en el municipio de Armero-Guayabal (CURDN– UT).

Fuente: Autor

Debido a las características que presenta esta especie, posterior al establecimiento de una plantación forestal, se debe implementar un conjunto de tratamientos silviculturales que busquen generar modificaciones en la estructura de la plantación, principalmente en el

control de la densidad. A lo largo de la vida de la plantación será necesaria más de una intervención que deberá basarse en el principio de “justo a tiempo” y que permitirá alcanzar los objetivos de producción propuestos (Rojas Rodríguez et al., 2004).

En Colombia la empresa Pizano S.A utiliza la madera de Melina para ebanistería, chapas, tríplex, muebles, tallas, torno, Instrumentos musicales, estructuras y artesanías. De igual forma la empresa Refocosta S.A produce madera de esta especie que se puede utilizar para madera en bruto, flejes de madera, lana de madera, harina de madera (Viruta y aserrín), madera aserrada, hojas para contrachapado, madera perfilada, tableros de partículas, tableros de fibra de madera, madera contrachapada, madera densificada (bloques, tiras o perfiles); también la utiliza en productos elaborados como: marcos de madera, cajones, cajas, barriles, cubas, tinas, piezas de carpintería para construcciones, artículos de mesa o cocina, estatuillas y demás objetos de adorno, demás manufacturas de madera, pulpa o pasta de madera, papel, productos editoriales y artes gráficas, suelas y tacones de madera, grandes embarcaciones, yates y embarcaciones de recreo o deporte, muebles de madera para oficina, muebles de madera para cocina y muebles de madera para dormitorios (González, 2004).

### 2.1.3 Tercera etapa: Establecimiento de Plantaciones

En esta etapa se tienen en cuenta los siguientes pasos:

- **Selección y adecuación del terreno.**

En general existen tres factores que en forma consistente se deben tomar en cuenta para la selección de nuevas áreas a reforestar, ellos son: la posición topográfica del sitio, los contenidos de calcio y magnesio en el primer horizonte y el uso anterior del suelo.

Aunque Gmelina arborea se adapta a una amplia variedad de condiciones edáficas y sobrevive con facilidad en una gran variedad de tipos de suelo; entre ellos ácidos, calcáreos limosos, suelos rojos o arcillosos; su mejor desarrollo lo alcanza en aquellos cuyas texturas varían de arenosas a francas, profundos, de origen aluvial, húmedos, bien drenados y aireados y ricos en bases (Rojas Rodríguez,2004).

Su mejor desarrollo se logra en suelos cuya textura varía de arenosa a limosa, profunda, de origen aluvial, húmedo, bien drenado y aireado y rico en bases. Sin embargo, como la especie Gmelina arborea se adapta a una amplia variedad de condiciones de suelo y

sobrevive fácilmente en una amplia variedad de tipos de suelo, incluyendo suelos ácidos, calcáreos, limosos, rojos o arcillosos, para este estudio se seleccionó el conjunto de parcelas permanentes del proyecto de reforestación comercial del Tolima”–3485 mencionado anteriormente, ubicados en los bosques secos tropicales del Tolima y distribuidas en cuatro municipios: Armero-Guayabal, Guamo, Coello y Espinal. Las edades varían desde los 2 años en algunas parcelas en la primera medición, hasta los 16 años en otras parcelas al momento de la quinta medición realizada y con densidades iniciales de siembra entre 900 – 1300 árboles/hectárea.

- **Sistemas de producción de plántulas en vivero**

La propagación de *G. arborea* para el establecimiento de plantaciones puede realizarse por medio de semillas o estacas enraizadas. Los proyectos pequeños de reforestación y agroforestería tienden a usar semillas para establecer la plantación, mientras que los grandes proyectos con programas de mejoramiento desarrollan el uso de estacas enraizadas (Rojas Rodríguez,2004).

- **Patrón y distancia de siembra.**

El patrón recomendado para la siembra de las plántulas es en forma de cuadrícula (figura nn)




Figura 15: Patrón y distancia de siembra

Fuente: <http://ecoursesonline.iasri.res.in/mod/page/view.php?id=1578>

De acuerdo con el Manual para productores de melina (*Gmelina arborea*) en Costa Rica, (Rojas Rodríguez, 2004). Los valores recomendados de densidad de plantación depende del objetivo final del cultivo, pero por lo general se planta entre 2.5 x 2.5 y 3.5 x 3.5 metros. La distancia de siembra más aconsejable es de 2.5 x 2.5 metros cuando se quiere producir leña o pulpa, y de 3.0 x 3.0 metros para producción de madera, astillas, aserrío o desenrollado.

### 2.1.3.1 Área de estudio

El estudio se realizó con información dasométrica proveniente de parcelas permanentes y temporales de muestreo en plantaciones forestales de Melina (*Gmelina arborea* Roxb.), establecidas en cuatro municipios del Departamento del Tolima: Armero-Guayabal (Centro Universitario Regional Del Norte -CURDN- Universidad del Tolima), Coello (Finca El Neme), Espinal (Corporación Colombiana de Investigación Agropecuaria – CORPOICA, Nataima) y Guamo (Finca Arizona, vereda Bellavista) (Figura 11). Estas parcelas se encuentran ubicadas en la zona climática clasificada, según (Holdridge, 1947), como bosque seco Tropical (Bs-T).

### 2.1.3.2 Muestreo de parcelas

Los datos fueron obtenidos de las mediciones realizadas a 41 parcelas circulares de *Gmelina arborea* Roxb., distribuidas así: 31 parcelas permanentes de muestreo, que hacen parte del conjunto de parcelas de monitoreo sobre el crecimiento y rendimiento de la especie en el Departamento del Tolima instaladas en el marco del desarrollo del proyecto “Desarrollo de un modelo de planificación para las plantaciones de *Tectona grandis* Linn F, *Gmelina arborea* Roxb, *Pinus patula* Schl, *Pinus oocarpa* Shiede y *Eucalyptus grandis* como apoyo a la consolidación del proyecto de reforestación comercial del Tolima” –3485, cofinanciado por el Ministerio de Agricultura y Desarrollo Rural en la convocatoria de Investigación, Ciencia y Tecnología del 2008 (CONIF, 2008); y 10 parcelas temporales establecidas en las plantaciones con que cuenta la Corporación Colombiana de Investigación Agropecuaria (CORPOICA) del municipio del Espinal.

Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de Inteligencia Computacional

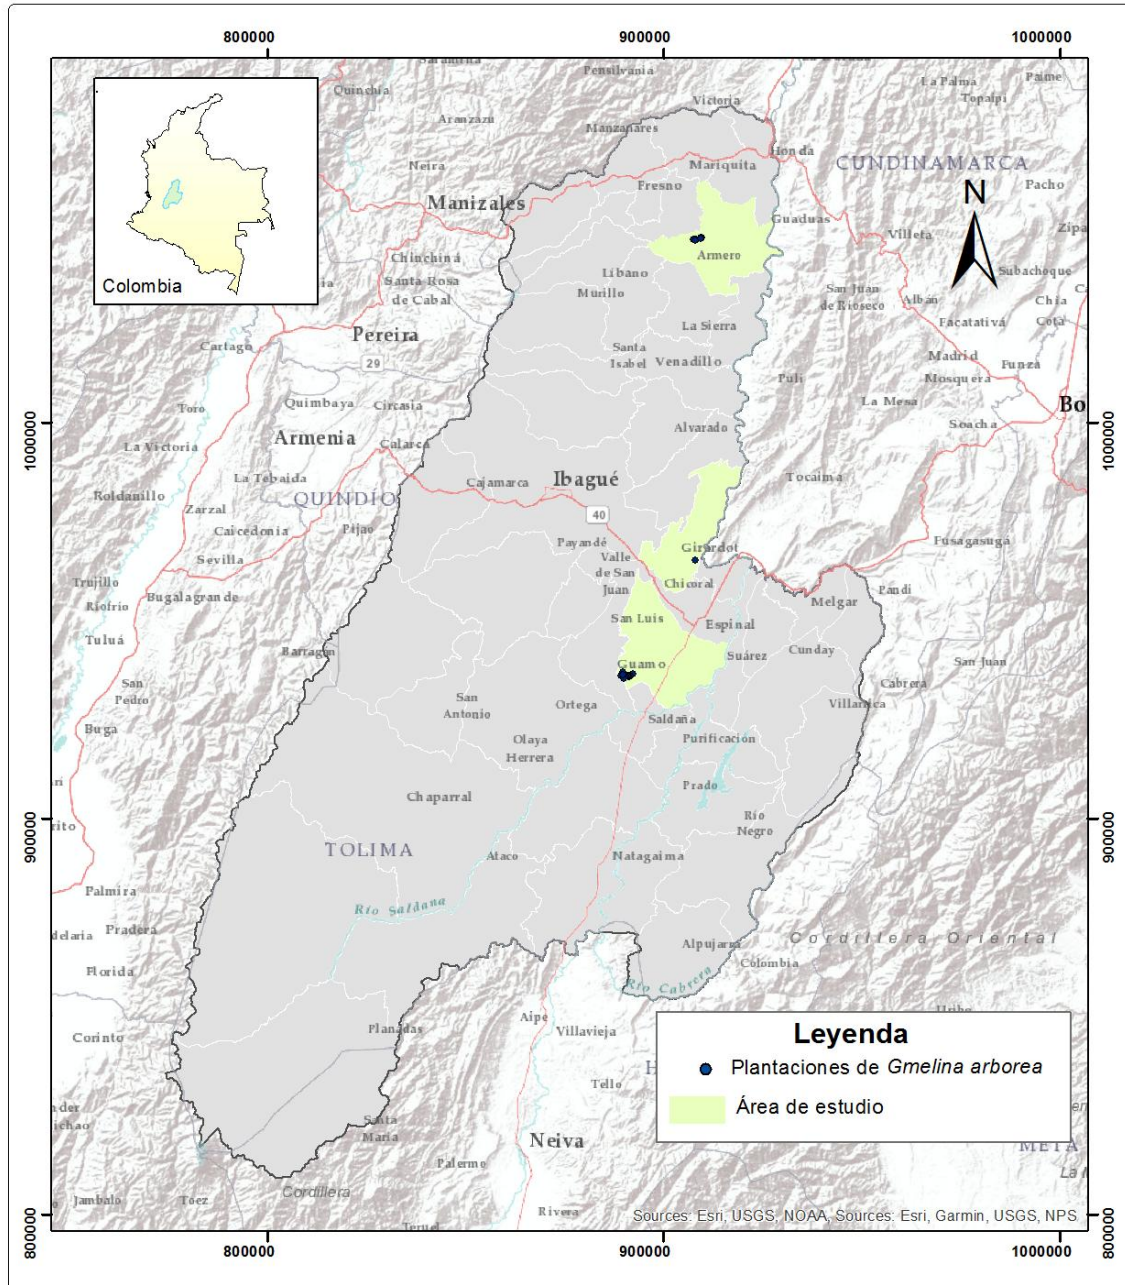


Figura 16: Plantaciones de *Gmelina arborea* Roxb, en el Departamento del Tolima.

Localización de los municipios donde se encuentran

Fuente: Autor

Las 31 parcelas permanentes cuentan con datos generales como: fecha de establecimiento, posicionamiento geográfico, ubicación del predio, altura sobre el nivel del

mar, densidad de siembra y superficie de la parcela; además de su código de identificación y datos particulares: número del árbol, ángulo y distancia respecto al centro de la parcela, calidad fustal, posición sociológica, diámetro normal (a los 1,30 m de altura, DAP), altura total (HT) y altura de comercial (HC). Las últimas mediciones tienen información de los radios de copa

Cada parcela cuenta con una superficie de 800 m<sup>2</sup> y un radio de 16 m. Para un total de 2.183 árboles medidos en las zonas de estudio. El presente estudio se realizó en tres localidades representativas del Departamento del Tolima: Armero Guayabal, donde se encuentra el Centro Universitario Regional Del Norte - CURDN- Universidad del Tolima, situado a 352 msnm, presenta una temperatura promedio de 26°C. Distante a unos 94 km de la ciudad de Ibagué, capital del mismo departamento. Guamo se encuentra ubicado a 42 Km de Ibagué, presenta una altura de 326 msnm y una temperatura promedio de 28°C. Coello cuenta con una ubicación geográfica estratégica, que presenta una altura de 329 msnm y una temperatura promedio de 26°C, encontrándose a 81 Km de Ibagué.

Otras variables consideradas al momento de la medición a nivel de árbol son la posición sociológica del árbol, que corresponde a tres categorías (ver Tabla 1), y la calidad fustal (ver Tabla 2), los valores fueron dados a criterio del ingeniero encargado de las mediciones.

Tabla 1: Posición sociológica del árbol en la parcela

Codificación de la categoría	Categoría
1	Dominante
2	Codominante
3	Suprimido

Tabla 3: Calidad fustal del árbol

Codificación de la categoría	Categoría
1	Bueno: árbol recto, cilíndrico, libre de ramas gruesas
2	Regular: árbol con inclinaciones leves, o un poco torcido.
3	Malo: árbol con defectos de forma, bifurcaciones y muy torcidos.

Ramos Molina y Niño López (2017), realizaron estudios de volumen sobre la especie en la región, la estimación de parámetros se realizó a través de métodos de regresión no lineal. Para este proceso se utilizó el procedimiento MODEL contenido en Statistical Analysis System - SAS, empleando el algoritmo de minimización de la suma de cuadrados de Marquardt (SAS Institute Inc., 1999).

Tabla 4: Modelos de Volumen

#	Modelo	Expresión matemática
M1	Spurr (1952)	$v = \beta_0 + \beta_1 \cdot d^2 \cdot h + e$
M2	Honer (1964)	$v = \frac{d^2}{\beta_0 + \frac{\beta_1}{h}} + e$
M3	Schumacher & Hall (1933)	$v = \beta_1 \cdot d^{\beta_2} \cdot h^{\beta_3} + e$
M4	Burkhardt (1977)	$v = \beta_0 + \beta_1 \cdot d^{\beta_2} \cdot h^{\beta_3} + e$

**Leyenda:**  $d$  el diámetro a 1.3 m del árbol (cm),  $h$  es la altura total del árbol (m),  $\beta_i$  son parámetros que estimar y  $e$  es el error aleatorio. Fuente: López et al. (2013)

De acuerdo con los resultados obtenidos en el trabajo de Ramos Molina y Niño López (2017), el modelo M3 Schumacher & Hall (1933) obtuvo el mejor desempeño.

#### 2.1.4 Cuarta etapa: Manejo de Plantaciones:

En esta etapa se debe implementar un conjunto de tratamientos silviculturales que buscan generar modificaciones en la estructura y producción de la plantación: la poda y el raleo. Estas intervenciones se deben realizar más de una vez y en diferentes etapas del crecimiento de la plantación.

### 2.1.4.1. Las podas:

En esta intervención se cortan las ramas inferiores del árbol con el propósito de evitar la formación de nudos en el tronco y así obtener mejor calidad de madera. Es una intervención de forma que no incide directamente en la producción.



Figura 17: Izquierda: Plantación de melina con poda, Derecha: Detalle de la poda de una rama gruesa

Fuente (Rojas Rodríguez,2004)

La poda debe realizarse en las primeras fases de desarrollo de la plantación. La propuesta de Ohland (2000) de poda para la melina se basa en el siguiente esquema: Una primera intervención podría aplicarse cuando la altura media de la plantación es de 4 m y el diámetro medio de 5 cm. En este caso, se aplica una poda de hasta 2 m. La segunda poda se puede realizar cuando la altura media de la plantación alcanza los 8 m y el diámetro medio es de 11 cm., tratando de favorecer únicamente a los árboles destinados a la recolección final. La altura de poda recomendada varía entre 3,5 y 4 metros. Una tercera intervención de poda se recomienda cuando la plantación alcanza una altura media de 12 m, donde se espera dejar un tronco libre de ramas de hasta 6 m de altura, en aquellos árboles que irán hasta la cosecha final. La aplicación de este esquema permitiría obtener un primer tronco de 2,55 m para uso en chapa o madera de sierra, un segundo tronco de 3,35 m para madera de sierra y un tercer tronco o más para productos que utilicen madera

de menores dimensiones y defectos por nudos. El momento adecuado para la poda, es al final de la estación seca, reduciendo el riesgo de infecciones fúngicas y ataques de insectos en los cortes de las ramas (Rojas Rodríguez,2004).

#### 2.1.4.2. Los raleos o raleos:

A medida que los árboles en la plantación van creciendo, sus copas y su sistema radical crecen hasta entrar en competencia y la tasa de crecimiento en volumen puede reducirse rápidamente. Cuando esto sucede, se hace necesario disminuir la densidad de la plantación cortando los árboles más pequeños para ejercer control sobre la capacidad de carga del sitio, la estructura de la plantación, la productividad, el tamaño de los árboles y el tiempo transcurrido hasta la cosecha final (Arias, 2004). A esta tarea se le denomina raleo o raleo. El objetivo final de los raleos será concentrar el potencial de crecimiento en los individuos de mayor desarrollo y mejor calidad de fuste, (Rojas Rodríguez,2004).

De acuerdo con la intensidad que se realice, se pueden clasificar los raleos en baja, media o alta intensidad:

En los raleos de baja intensidad se cortan los árboles denominados suprimidos que serán aquellos que por genética o disposición de recursos no presentan buen crecimiento. Los raleos de mediana intensidad son aquellos donde se cortan tanto los árboles suprimidos como los árboles denominados intermedios, que tampoco presentan buen crecimiento. Finalmente, en los raleos de alta intensidad solo se dejan aquellos árboles de mayor desarrollo y mejor calidad de fuste.




Figura 18: Diagrama de intensidad de raleado

Fuente: <https://forestrypedia.com/thinning-detailed-note/>

En Colombia, consultados los expertos, la política que se recomienda para el manejo de la densidad de la especie *Gmelina arborea* Roxb., en plantaciones ubicadas en los bosques secos tropicales es: un primer raleo con intensidad del 40% de los árboles de menor diámetro en el año 3 y un segundo raleo con intensidad del 30% de los árboles de menor diámetro en el año 6. Para un aprovechamiento final al año 10 o 12.

	$t=1$	$t=2$	$t=3$	$t=4$	$t=5$	$t=6$	$t=7$	$t=8$	$t=9$	$t=10$
$\pi_{\text{estandar}}$	0	0	40	0	0	30	0	0	0	0
	$p_1, p_2, \dots, p_{10} \leq 80\%$									

Figura 19: Representación de la política de raleo para la especie *Gmelina arborea* Roxb., recomendada, donde  $t$ = año,  $\pi$ = intensidad de raleo en porcentaje de árboles a cortar.

Fuente: Autor

- Estudios experimentales de otras políticas de raleo.

Tabla 5: Resultado de Tratamientos Experimentales de intensidad de Raleo

Cuadro 17. Efecto de raleos fuertes en el crecimiento de melina a los 8 años						
Tratamiento		Mortalidad inicial (%)	N (arb ha <sup>-1</sup> )**	Dap (cm)	G (m <sup>2</sup> ha <sup>-1</sup> )	V (m <sup>3</sup> ha <sup>-1</sup> )
Resultante	Previo*					
T1 (60%)	30% - 30%	2,2	366	27,69	22,29	207,08
T2 (70%)	35% - 35%	2,8	302	34,28	28,33	255,49
T3 (80%)	40% - 40%	4,2	175	33,91	16,22	150,99
* Raleos realizados a los 3 y 6 años de edad						
** Densidad resultante (árboles ha <sup>-1</sup> ) a los 8 años						
Fuente: tomado de Vallejos et al. (2015).						

Tomado de: Martínez H, 2015

La tabla 4 muestra las 3 políticas de raleo (tratamientos) implementadas experimentalmente para determinar el efecto de raleos de alta intensidad en el crecimiento de la especie *Gmelina arborea* Roxb., en diámetro y volumen a los 8 años. La política de raleo T2 que contempla 2 raleos, el primero en el tercer año de establecimiento, con una intensidad del 35% y un segundo raleo en el sexto año de edad de la plantación de experimentación, con una intensidad también del 35% obtuvo el mejor rendimiento, con un volumen final de 255,49 metros cúbicos por hectárea (vallejos et al.,2015).

### 2.1.5. Quinta etapa: Aprovechamiento (cosecha final):

La tala total de la plantación (cosecha final), es una de las etapas finales del sistema de producción de madera de plantación. Sin embargo, la prescripción y aplicación de raleos, cuyo producto tiene características para la transformación industrial, hace que incluso años antes de llegar a la fase final, comiencen los trabajos de aprovechamiento (Rojas Rodríguez,2004).

En general, cuando se aprovecha una plantación forestal, el objetivo es obtener la mayor cantidad de producto, de la mejor calidad posible, al menor coste y con el menor impacto posible, tanto sobre el medio ambiente como sobre la masa residual en el caso de una entresaca (raleo) (Rojas Rodríguez,2004).



## 2.2 Definición del problema:

En este trabajo se plantea el manejo del factor más crítico en la producción, **los raleos**, usando herramientas **de inteligencia computacional**, con el fin de mejorar la producción (i.e. la rentabilidad) de las **plantaciones forestales de la especie *Gmelina arborea* Roxb. para hacerlas una inversión más atractiva.**

Dada la variabilidad de los factores externos por el entorno y los factores internos por la genética individual de los árboles en la plantación, estos no crecen al mismo ritmo. Por tanto, el proceso de manejo de los raleos en la producción de la especie *Gmelina arborea* Roxb. Se puede describir como un proceso de decisión secuencial bajo incertidumbre (S,A,N,u), donde:

S : conjunto de posibles estados del sistema.

A : conjunto de posibles acciones o decisiones del agente.

N : conjunto de respuestas de la naturaleza (incertidumbre).

u : función de utilidad que depende del estado inicial, las acciones y el estado final.

Desde este punto de vista, la representación del Modelo para maximizar el volumen de madera a través de la búsqueda de una política óptima de raleos lo describe formalmente un Proceso de decisión de Markov (MDP por sus siglas en inglés) con restricciones.

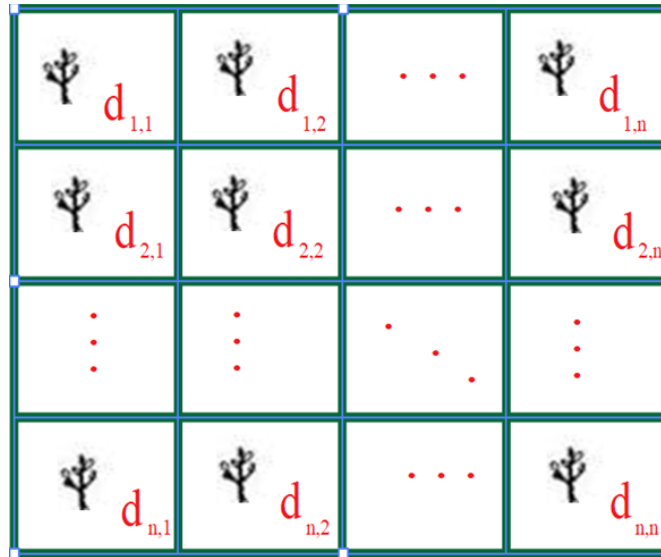


Figura 20: Representación gráfica del espacio de estados del proceso MDP con restricciones.

Fuente: Autor

- **Espacio de estados** -  $S = G \times D$  (continuo) donde

$G$  = Retícula espacial regular finita de localizaciones de los arboles (discreto)

$D$  = Diámetro de los arboles (continuo)

La única decisión manejo que se considera en este trabajo son los raleos. Se define una política  $\pi$  como una regla que establece para cada año  $t = 1, 2, \dots, 9, 10$  el porcentaje  $p_1, p_2, \dots, p_{10}$  de los árboles que quedan se ralean cada año ordenados de menor a mayor por el diámetro sobre el índice de competencia que mide el nivel de competencia que tiene un árbol por parte de sus vecinos y el cual está basado en el diámetro del árbol y los diámetros y distancias de sus vecinos.




Figura 21: Representación de la política de raleo para la especie Gmelina arborea Roxb., a encontrar, donde  $t$ = año,  $P_i$ = intensidad de raleo en porcentaje de árboles a cortar

Fuente: Autor

- Tiempo discreto finito  $T=\{1,2,\dots,10\}$
- Espacio de acciones  $A= G \times \{0,1\}$  Para cada árbol en la retícula  $G$ , en cada periodo  $t$ , se decide si se ralea 1 o no se ralea 0 , hasta alcanzar el porcentaje que establezca la política para ese periodo. Esto se hace de menor a mayor según diámetro de árbol dividido por su índice de competencia, que depende de su diámetro y los diámetros distancias de sus vecinos el índice de competencia se recalcula cada vez que se ralea un árbol.
- Funcional de utilidad  $V$  aditivo Se usa como funcional de utilidad  $V$  el volumen total de madera producido que esta se calcula como la adición de los volumen de madera en los raleos más el volumen de la cosecha al final de año 10. El valor del funcional de utilidad cuando se aplica una política  $\pi$  se denota  $V_{\pi}$ .

En el siguiente diagrama de influencia Howard y Matheson 1984 (ver figura 16), se representa el flujo de transición entre estados durante los  $t$  periodos: Al aplicar la acción  $A$ , determinada en la política  $\pi$  de raleo con una intensidad  $P1$ , sobre el espacio de estado (densidad  $G \times D$ ) del sistema  $S$  en el instante de tiempo  $t=1$ , la respuesta de la naturaleza  $N$  será el espacio de estado  $S$  en el siguiente instante del tiempo  $t=2$  y generando un valor aditivo en el valor funcional de utilidad  $u$ . este procedimiento continua periódicamente desde  $t=2$  hasta  $t=10$ .

La **política mejorada**  $\pi^*$ , dada una estructura probabilística sobre los **Diámetros Iniciales del año 1** de los árboles, notados **DI** y los cuales se distribuyen de manera normal comedia 4.6 cm y desviación estándar 1.52 cm.

$$DI \sim N(4.36\text{cm}, 1.52\text{cm}) ,$$

es la que mejora el valor esperado del funcional de utilidad  $V_{\pi}$  sobre todas las políticas  $\pi$

$$V_{\pi^*} = \max_{\pi} E_{G \times DI} [V_{\pi}]$$

Se usa como función de utilidad  $V$  el **volumen de madera producido** que se calcula como la **adición** de los **volúmenes de madera en los raleos** más el **volumen de la cosecha al final de año 12**. El valor de la función de utilidad cuando se aplica una política  $\pi$  , se denota  $V_{\pi}$

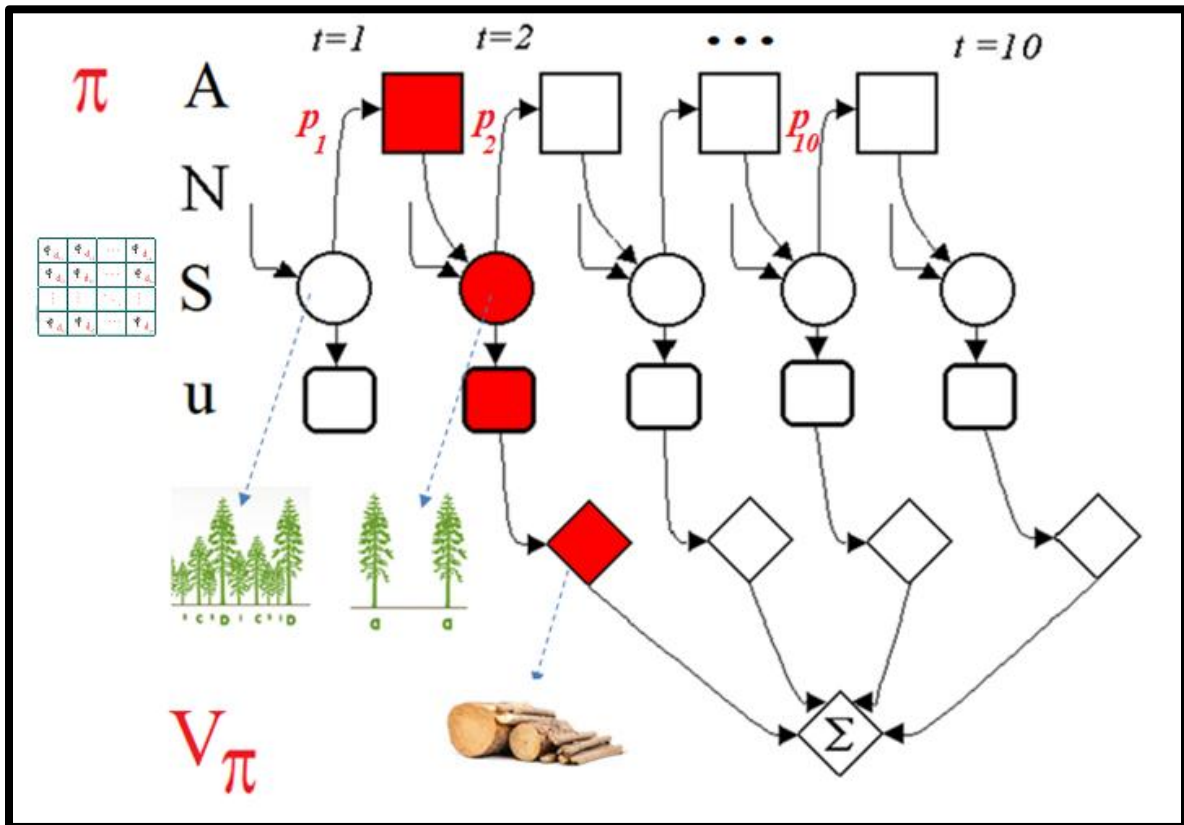


Figura 22: Diagramas de influencia de aplicación de políticas de raleo

Fuente: modificado de Howard y Matheson, 1984

La **política mejorada**  $\pi^*$ , dada una estructura probabilística sobre los **Diámetros Iniciales del año 1** de los árboles, notados **DI** y los cuales se distribuyen de manera normal con media 4.6 cm y desviación estándar 1.52 cm.

$$DI \sim N(4.36\text{cm}, 1.52\text{cm}),$$

es la que mejora el valor esperado del funcional de utilidad  $V_\pi$  sobre todas las políticas  $\pi$

$$V_{\pi^*} = \max_{\pi} E_{G \times DI}[V_\pi]$$

Se usa como función de utilidad  $V$  el **volumen de madera producido** que se calcula como la **adición** de los **volúmenes de madera en los raleos** más el **volumen de la cosecha al final de año 12**. El valor de la función de utilidad cuando se aplica una política  $\pi$ , se denota  $V_\pi$

Como el modelo es un MDP con restricciones la solución es **NP-Hard** ("Computational Complexity in Markov Decision Theory", Tsitsiklis, 2014) así que es viable considerar soluciones aproximadas como las que producen técnicas metaheurísticas.

El objetivo es buscar una política que supere la política estándar de los expertos

## 2.3 Objetivo general

Optimizar la producción de madera para la especie promisoria *Gmelina arborea* Roxb. en Colombia, utilizando técnicas de inteligencia computacional

## 2.4 Objetivos específicos:

Par cumplir con el objetivo general, se plantean 2 objetivos específicos:

### 2.4.1 Objetivo específico 1:

Modelar una plantación mediante autómatas celulares que representan el crecimiento del árbol incluyendo el efecto de las interacciones locales (competencia)

Para la solución del primer objetivo específico se desarrolló un simulador en dos fases:

- **Fase1 . Modelo de crecimiento del árbol (RNA):** Implementación de una Red Neuronal Artificial (RNA) para modelar el crecimiento de un árbol considerando la competencia de los árboles vecinos
- **Fase 2. Simulador de crecimiento de la plantación forestal (AC):** Construcción de un simulador de crecimiento de la plantación forestal como un Autómata Celular (AC) con una RNA en cada nodo modelando cada árbol

### 2.4.2 Objetivo específico 2:

Encontrar una "buena" decisión de estrategias de gestión para la plantación utilizando el modelo desarrollado en el objetivo 1 y algoritmos evolutivos

Para cumplir con el segundo objetivo específico se realizó una tercera fase encargada del Mejoramiento de la política de manejo de raleo (AG):

- **Fase 3. Mejoramiento de la política de manejo de raleo (AG):** Mejoramiento de política de manejo de los raleos usando un Algoritmo Genético (AG)

En general, para el manejo del raleo, la literatura muestra que se implementan ensayos forestales que, por su naturaleza, requieren largos periodos de tiempo para obtener los resultados deseados, se encontró que a partir de estos ensayos se agregan ya sea por adición o multiplicación ecuaciones a los modelos alométricos como intentando corregir las modificaciones a los parámetros por efecto de esta intervención. En razón a que el modelo propuesto de manejo de rodal (autómatas celulares) incluye la competencia, intrínsecamente se asumen los efectos del raleo. En síntesis, con la realización de los objetivos propuestos se aporta a la toma de decisiones, con una herramienta para obtener una buena política de tiempos e intensidad de raleos.

### 3 FASES DEL DESARROLLO METODOLÓGICO

La metodología para el desarrollo de los objetivos planteados de este trabajo se dividió en 3 fases:



Figura 23:Relación entre los objetivos propuestos y su desarrollo metodológico

Fuente: El autor

La figura 23 muestra gráficamente la relación entre los objetivos específicos propuestos y su desarrollo en 3 fases, las 2 primeras que conforman un simulador del crecimiento de una plantación y una tercera fase de mejoramiento de las políticas de raleo.

### 3.1 FASE 1. MODELO DE CRECIMIENTO DEL ÁRBOL

En la primera fase para modelar el crecimiento del árbol individual primero se realizó un estudio de índices de competencia de acuerdo a la literatura, para escoger el que más aporte al modelo de crecimiento, en cuanto al árbol se modeló primero con una ecuación empírica que sirva de referencia para validar el modelado del árbol con una Red Neuronal Artificial.

#### 3.1.1 Modelo de crecimiento con índice de competencia

Se implementó un modelo de crecimiento de árbol individual basado en la información dasométrica. Los modelos forestales de crecimiento y rendimiento responden a modelos empíricos que se generan a partir de regresiones lineales multivariadas de las mediciones de campo sobre los árboles de las parcelas, sean estas permanentes o temporales, árboles individuales y mediciones de la parcela (CONIF, 2011). El Diámetro Normal (DAP) es la variable independiente típica debido a la precisión y facilidad de su obtención. La medición de la altura de los árboles, por ser muy dispendiosa, inexacta, debido a que depende mucho del criterio del observador, y costosa, se realiza sobre una tercera parte de los árboles que hacen parte de la parcela de medición, para luego ser completados por medio de regresiones lineales a partir de las mediciones de diámetro (CONIF, 2011). Las variables más importantes a nivel de rodal son la densidad y la edad del rodal, así como el cálculo del diámetro medio cuadrático (G), el Índice de Sitio (IS) y el Índice de Densidad del Rodal (IDR)

En los índices de competencia dependientes de la distancia, se hace necesario elegir un criterio de selección del árbol objetivo (Crecente Campo et al., 2007); en este trabajo para determinar el índice a utilizar en el modelo final, se dividieron los datos de cada parcela de acuerdo al estrato sociológico: dominante, codominante, intermedio y suprimido; y se calcularon los índices de competencia sobre el árbol promedio de cada categoría, teniendo en cuenta que el árbol seleccionado no se encuentre en el borde de la parcela e igualmente que todos sus competidores estén dentro de la parcela inventariada.

Con el ánimo de estudiar la influencia de la competencia en el crecimiento en diámetro y altura de los árboles mediante índices de competencia (IC) tanto dependientes como independientes de la distancia (ver Tablas 4 y 5), se establecieron tres tipos de relaciones (Modelos crecimiento - Índice de competencia) que incorpora a cada uno de los índices de competencia evaluados: lineal, exponencial y potencial (Crecente Campo et al., 2007):

- $\Delta y = \alpha + \beta \cdot IC$  (3.1)

- $\Delta y = \alpha \cdot \exp(\beta \cdot IC)$  (3.2)

- $\Delta y = \alpha \cdot IC^\beta$  (3.3)

Donde  $y$  es la variable por modelizar (diámetro normal o altura),  $IC$  es el resultado de cada uno de los índices de competencia y  $\alpha$  y  $\beta$  son los parámetros para estimar en los ajustes por regresión.

Los principales factores que pueden afectar o favorecer el crecimiento de la plantación son: calidad de sitio, edad del árbol, densidad e intensidad de la competencia que ejercen los árboles que lo rodean, recursos como el agua, la luz y los nutrientes. Por tanto, un modelo de crecimiento de diámetro de árbol individual debe tener en cuenta estos factores. Por ello se plantearon los modelos lineales (Álvarez-Taboada, Barrio-Anta, Gorgoso Varela, et al., 2003) :

Modelo lineal que relaciona el logaritmo natural de: edad  $t$ , diámetro de partida  $d$ , índice de sitio  $IS$  y densidad  $N$  (Ecuación (3.4)).

$$\ln(\Delta D) = a_1 + a_2 \cdot \ln(t) + a_3 \cdot \ln(d) + a_4 \cdot \ln(IS) + a_5 \cdot \ln(N) \quad (3.4)$$

Modelo lineal que relaciona el logaritmo natural de: edad  $t$ , diámetro de partida  $d$ , índice de sitio  $IS$ , densidad  $N$ , vecinos  $Vc$  e índice de competencia  $IC$ . (Ecuación (3.5)).

$$\ln(\Delta D) = a_1 + a_2 \cdot \ln(t) + a_3 \cdot \ln(d) + a_4 \cdot \ln(IS) + a_5 \cdot \ln(N) + a_6 \cdot \ln(Vc) + a_7 \cdot \ln(IC) \quad (3.5)$$

Modelo lineal que relaciona el Índice de competencia  $IC$  y el logaritmo natural de: edad  $t$ , diámetro de partida  $d$ , índice de sitio  $IS$  y densidad  $N$  (Ecuación (3.6)).

$$\ln(\Delta D) = a_1 + a_2 \cdot \ln(t) + a_3 \cdot \ln(d) + a_4 \cdot \ln(IS) + a_5 \cdot \ln(N) + a_6 \cdot IC \quad (3.6)$$

Dónde:  $\Delta D$  es el crecimiento en Diámetro entre dos mediciones expresado en  $\text{cm}^2$ ,  $t$  es la edad en años,  $d$  es diámetro normal inicial en  $\text{cm}$ ,  $IS$  el índice de sitio en metros,  $N$  es el número de pies (árboles) por hectárea,  $IC$  es el índice de competencia y  $a_i$  son los parámetros para estimar en el ajuste.

A partir de los resultados obtenidos en el proyecto de “*Evaluación de estrategias para la estimación del volumen total de árboles individuales de Gmelina Arborea creciendo en Armero-Tolima*” por Ramos Molina y Niño López (2017), que se realizó al cosechar los árboles de los rodales de la granja experimental que pertenece a la Universidad del Tolima en Armero, y donde estaban establecidas siete de las parcelas que hacen arte de este trabajo, se modeló el volumen de los árboles.

### 3.1.2 Manejo de la Densidad del Rodal

La densidad del rodal se puede manejar en el desarrollo de un rodal a través de acciones de raleo, el cual es un tratamiento silvicultural que permite alcanzar los objetivos de producción propuestos para la plantación ya sea antes o después de que los árboles hayan alcanzado un tamaño comercial, y se utiliza para concentrar los recursos ambientales finitos del sitio en unos pocos árboles de cultivo individuales seleccionados. Por lo tanto, al reducir la densidad del rodal, el raleo generalmente reduce la competencia intraespecífica y aumenta la disponibilidad de luz y nutrientes para los árboles residuales, mejorando así su crecimiento y reduciendo la edad de rotación para lograr un tamaño de árbol objetivo (Thiffault et al., 2021).

Incluso, Pretzsch (2020) menciona que algunos autores plantean la hipótesis de que la aceleración del crecimiento después del raleo puede deberse a la mejora de la renovación

de nutrientes en el suelo y al suministro de nutrientes de la copa estimulados por la apertura de los rodales o por la eliminación de árboles moribundos con baja eficiencia en el uso del agua a favor de los vecinos vitales más eficientes. Sin embargo, como cita Messerer (2020), la respuesta al raleo depende de la edad de los rodales, así como de la tolerancia a la sombra de la especie. En términos generales, los árboles más jóvenes muestran una mayor respuesta de crecimiento que los rodales más viejos. Por lo que se puede decir que la respuesta del crecimiento al raleo varía según la especie de árbol, la edad del árbol y la intensidad del raleo.

Thiffault (2021) menciona que, en la silvicultura de plantación, la densidad del rodal se puede gestionar en la etapa de inicio de la plantación variando la distancia entre los árboles plantados. Mientras que las densidades de plantación más altas dan como resultado un mayor volumen de producción a nivel de rodal porque se optimiza la ocupación del sitio, el tamaño de los árboles individuales se maximiza a una densidad más baja debido a la reducción de la competencia intraespecífica.

Con el propósito de describir la densidad y planificar raleos, se han utilizado factores como la misma densidad, la composición, la estructura, el sitio y la edad del rodal para el desarrollo de diferentes índices, los que se pueden encontrar en la literatura y que son descritos por Corvalán y Hernández (2006) de acuerdo a las variables dasométricas de la siguiente manera:

- Número de árboles;
- Número de árboles y altura; utiliza la altura dominante del rodal como expresión de su tamaño y el número de árboles que contiene, donde el Índice de espaciamento relativo es el más utilizado.
- Número de árboles, diámetro normal y altura; encontrando con ellos el Área Fustal del Rodal, utiliza funciones de ahusamiento para expresar la superficie fustal de sus individuos, y Volumen del rodal, añade al área fustal un factor de forma de los árboles.
- Número de árboles y DAP; combina el tamaño de los árboles (DAP) del rodal y el número de árboles que lo compone. Donde Área basal por hectárea, es la suma por unidad de superficie de todos los fustes a nivel del DAP. Razón de área por árbol, supone que cada árbol genera un área de ocupación, por ende, el área total de

ocupación es igual a la suma del área ocupada por todos los árboles. Factor de competencia de copas, fórmula que los árboles que crecen aislados pueden expresar el diámetro de su copa como una función lineal de su DAP. Índice de densidad del rodal definido inicialmente por Reineke relaciona el número de árboles por unidad de área con su diámetro medio cuadrático.

Entender los diferentes estudios que se tienen de la densidad, como son el Índice de Densidad, y las zonas de densidad, incluyendo su valor máximo ( $IDR_{max}$ ), aportan al modelado y simulación, al determinar las restricciones en el modelo de crecimiento del rodal.

### 3.1.3 RNA como modelo de crecimiento

Los modelos lineales tanto matemáticos como estadísticos disponibles han mostrado ser efectivos para modelar el crecimiento medio de un árbol, aunque se sabe que existen relaciones no lineales entre los factores que determina el crecimiento del árbol en especial cuando se introduce el índice de competencia sobre un árbol de los árboles vecinos, las relaciones no lineales no se incorporan porque no parecen influir de manera significativa el crecimiento medio. La situación es diferente cuando se quiere modelar el comportamiento individual diferenciado de un árbol dentro de una plantación, en ese caso las relaciones lineales si influyen de manera significativa, los modelos disponibles tampoco permiten incorporar la variabilidad genética implícita que es fundamental para modelar el comportamiento individual diferenciado. Una RNA si permite modelar las relaciones no lineales entre los factores que determina el crecimiento del árbol e incorporar la variabilidad genética implícita.

### 3.1.4 Consideraciones de diseño de una Red Neuronal

Selección de las características/variables para la Implementación de una Red Neuronal Artificial (RNA) que modelar el crecimiento de un árbol considerando la competencia de los arboles vecinos.

Los pasos más relevantes al momento de diseñar una Red Neuronal Artificial son: la determinación del número de capas con la que se modelará el sistema, la cantidad de

neuronas que configuran cada capa, la función de activación de las neuronas y el algoritmo de retro propagación del error.

En la arquitectura de una Red Neuronal, el número de neuronas de la capa de entrada y la capa de salida están dados por el número de variables que defina el problema a modelar, mientras que el número de neuronas de la capa o capas ocultas, deben ser elegidos por el diseñador, dado que no existe un método o regla que ayude a determinar el número óptimo de neuronas ocultas para resolver un problema dado. En la mayor parte de las aplicaciones prácticas, estos parámetros se determinan por prueba y error, por lo que deben ser determinadas por el diseñador teniendo en cuenta básicamente el costo computacional.

El algoritmo o regla de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la Red Neuronal. En el caso de la Red Multicapa se utiliza un algoritmo de aprendizaje supervisado, es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida deseada.

Puesto que el objetivo es que la salida de la red sea lo más próxima posible a la salida deseada, el aprendizaje de la red se formula como un problema de minimización del error  $\min(E(x))$ , donde  $E(x)$  es la función que evalúa la diferencia entre las salidas de la red y las salidas deseadas (Ecuación 3.7); minimización que se consigue a través de la retro propagación del error encontrado, cambiando el conjunto de parámetros de la red-pesos y umbrales:

$$E(x) = \frac{1}{N} \sum_{n=0}^N e(n) \quad (3.7)$$

donde  $N$  es el número de entradas o muestras y  $e(n)$  es el error cometido por la red para la muestra  $n$ , dado por:

$$e(n) = \frac{1}{n_c} \sum_{i=1}^N (s_i(n) - y_i(n))^2 \quad (3.8)$$

Donde  $s(n)$  es la salida deseada,  $y(n)$  es la salida del sistema.

Por tanto, el aprendizaje de la Red Multicapa es equivalente a encontrar un mínimo de la función error. El procedimiento más utilizado está basado en métodos del gradiente estocástico, los cuales consisten en una sucesiva minimización de los errores para cada muestra  $e(n)$ , en lugar de minimizar el error total  $E(x)$ . Aplicando el método de descenso del gradiente estocástico, cada parámetro  $w$  de la red se módica para cada muestra de entrada  $n$  de acuerdo con la siguiente ley de aprendizaje. Ecuación 3.9:

$$w(n) = w(n - 1) - \alpha \frac{\partial e(n)}{\partial w} \quad (3.9)$$

donde  $e(n)$  es el error para la muestra  $n$  dado por la Ecuación (3.8), y  $\alpha$  es la razón o tasa de aprendizaje, parámetro que influye en la magnitud del desplazamiento en la superficie del error.

### 3.1.5 Implementación de la Red Neuronal Artificial

Las redes neuronales se componen de elementos simples que funcionan en paralelo. Estos elementos se inspiran en los sistemas nerviosos biológicos. Como en la naturaleza, las conexiones entre elementos determinan en gran medida la función de la red. Se puede entrenar una red neuronal para realizar una función particular ajustando los valores de las conexiones (pesos) entre sus elementos (Beale et al., 2014).

Se implementó un entrenamiento supervisado, que es el tipo de entrenamiento utilizado para modelar funciones de crecimiento. Para este tipo de entrenamiento, a partir de las mediciones de campo, se entregan a la red las entradas al modelo y la salida deseada, la cual se compara con la salida de la red, si las salidas (obtenida y deseada) se diferencian (superan un límite de error), los valores de las conexiones (pesos) entre los elementos de la red (neuronas) se modifican con base en un algoritmo de retro propagación del error, repitiendo este proceso de manera cíclica hasta lograr que converjan las salidas.

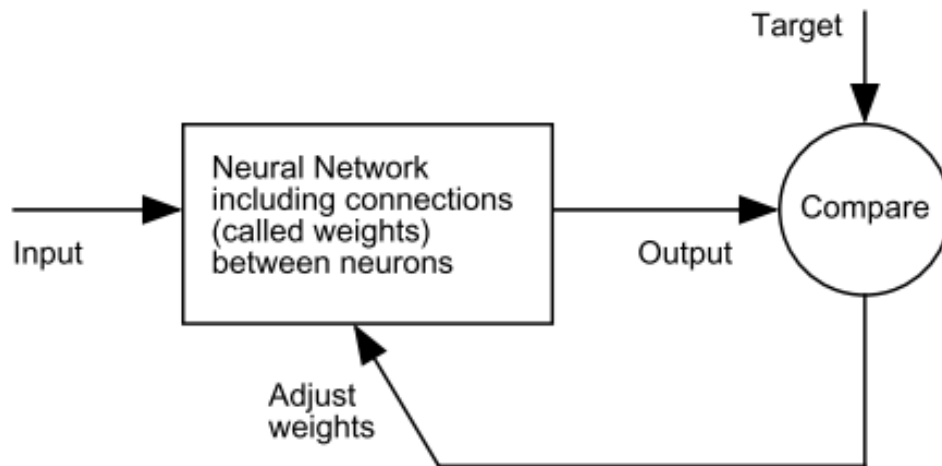


Figura 24: Diagrama del entrenamiento supervisado de la red neuronal artificial.

Fuente: Beale et al. (2014)

La tasa de aprendizaje ( $\alpha$ ) es un parámetro que determina la velocidad a la que van a cambiar los pesos de las conexiones de la red. Tiene generalmente un rango  $[0,1]$ , siendo los valores más cercanos a cero los que hacen que los pesos cambien poco a poco, acercándose lentamente a la convergencia, y los cercanos a uno los que hacen que la red converja más rápidamente al principio, pero siendo posible que los pesos oscilen demasiado al encontrar el peso óptimo final. Por esta razón es importante encontrar una tasa de aprendizaje óptima. Aquí es donde entra en juego un segundo término llamado momento ( $\eta$ ), que pondera cuanto queremos que influya lo que los pesos han cambiado en la anterior iteración. Con ello, sabremos que si los pesos han cambiado mucho es que estamos aún lejos del valor de la tasa de aprendizaje óptimo, por lo que se avanzará en su búsqueda más rápidamente.

### 3.1.6 Especificaciones de la Red

A partir de las diferentes mediciones sobre las parcelas permanentes y luego de un análisis de los datos, se generó un archivo en con 3.615 registros con la siguiente información: Numero de la parcela, Número del árbol, Número de la medición, Posición sociológica, Calidad fustal, Edad, Número de vecinos, Índice de Competencia de Hegyi, Índice de Sitio, Diámetro Normal, Altura Total y Altura de Copa:

Número de la parcela	Número de árbol	Número de la medición	Posición sociológica	Calidad fustal	Edad	Número de vecinos	IC	IS	DN	HT	HC
----------------------	-----------------	-----------------------	----------------------	----------------	------	-------------------	----	----	----	----	----

Figura 25: Información de mediciones de campo (variables dasométricas)

Fuente: Autor

Para el entrenamiento de la red neuronal artificial, a partir del conjunto de datos de mediciones se construyó la Matriz de entrada que cuenta con siete (7) variables (Posición, Edad, Delta de Edad, Número de árboles competidores, Diámetro, Índice de sitio e Índice de competencia) con 2649 muestras, y un vector de salida (Objetivo) que cuenta con una (1) variable (delta de crecimiento), con 2649 muestras

El 80% de los datos se destinó al entrenamiento, el 20% restante para prueba.

### 3.1.7 Arquitectura de la Red Neuronal Artificial

Se implementó un modelo de RNA de tipo perceptrones multicapa sobre MatLab, como se muestra en la tabla 6, sobre esa red se modificaron las entradas, en Figura 25, 26 y 27. Una primera red sin la competencia y las dos siguientes con competencia, con función de activación 'trainlm'.

La red está compuesta por una capa de entrada con 5, 7 y 8 neuronas para los tres casos, que conecta a una capa oculta con 70 neuronas con función de activación 'trainlm' y una capa de salida de una neurona con función lineal ('linear').

Tabla 6: Arquitectura de la red propuesta

Capa (tipo)	Número de neuronas	Función de activación	Param #
dense_1 (Dense)	(70)	trainlm	420, 560, 630
dense_2 (Dense)	(1)	Linear	71

A continuación, se presentan los diagramas para cada caso donde:  $Posc$  se refiere a la posición,  $t$  a la edad en años,  $Dt$  es el delta de la edad,  $DN$  es el diámetro normal,  $vec\_ini$  son los vecinos iniciales,  $vec\_fin$  son los vecinos finales,  $IC$  es el Índice de competencia,  $IS$  es el Índice de sitio y  $Dd$  es el delta de diámetro.




Figura 26: Diagrama de red neuronal de una capa oculta con cinco entradas




Figura 27: Diagrama de red neuronal de una capa oculta con siete entradas




Figura 28: Diagrama de red neuronal de una capa oculta con ocho entradas

Fuente: Autor

En el crecimiento de la plantación intervienen muchos factores, como la calidad del sitio (Barrios-Trilleras et al., 2021), la edad del árbol, la densidad y la intensidad de la competencia por recursos como el agua, la luz y los nutrientes. Por lo tanto, se propusieron

---

modelos de crecimiento del diámetro de árboles individuales para tener en cuenta la mayoría de estos factores, como se muestra en la Figura 13 y las Ecuaciones (3.5) y (3.6). De esta manera la RNA modela la dinámica del crecimiento del árbol individual.

## 3.2 Fase 2. Simulador de crecimiento de la plantación forestal (AC)

### 3.2.1 Implementación de la Red de Autómatas Celulares

Una vez determinado el modelo de crecimiento para el árbol individual, sensible a la competencia, se generó la Red de Autómatas Celulares, con el objetivo de simular el crecimiento del rodal. Para su construcción se tiene como base en el artículo "*Comparison of a cellular automata network and an individual-based model for the simulation of forest dynamics*" (Lett et al., 1999):

Para este caso, se representa la plantación como una grilla 2D y cada árbol de la plantación como una célula del autómata que está localizado en un determinado punto de la grilla. La dinámica del autómata representa el crecimiento de cada árbol en función de la interacción con las variables del ambiente, así como con los otros árboles de la misma especie que los circundan. Esta representación permite que el modelo de un rodal o una plantación se pueda considerar como un Autómata Celular (AC).

La implementación de la red se realizó mediante Scripts en la herramienta MatLab, donde se consideró una red de autómatas celulares de dos dimensiones con el modelo de vecindad Moore (9-vecinos) donde cada celda representa un árbol con sus correspondientes coordenadas (x, y) y su estado está representado en las variables: posición sociológica, edad, diámetro normal, vecinos vivos, Índice de Competencia de acuerdo con sus vecinos, e Índice de Sitio.

La simulación no tiene inconvenientes en las fronteras por tener el mismo comportamiento de un rodal, donde los árboles de las fronteras crecen con menos competidores, y esto lo tiene en cuenta la simulación.

La red simula una plantación de una hectárea, para lo cual genera las coordenadas de 1089 árboles sembrados a tres metros de distancia en forma rectangular, un vector de 1089 unos que representa en primera instancia que todos los árboles están vivos




Figura 29: Distribución de los vecinos en una RAC de 2 dimensiones. Vecindad de von Neumann (Izquierda) y vecindad de Moore (derecha). Fuente: Lett et al. (1999)

Basados en los porcentajes de árboles que corresponden a las categorías de la posición sociológica, en las mediciones realizadas, y a partir de un vector de 1089 posiciones que contiene valores aleatorios entre uno y 100 con distribución normal, con los que se obtiene las posiciones sociológicas de los árboles en el rodal simulado e igualmente el valor del diámetro normal (DN) inicial para el año 1: los valores aleatorios menores a 14,7 serán tomados como posición sociológica 4 -suprimidos y su diámetro inicial será un valor aleatorio con media 1,5 y desviación estándar 2,9. Los menores a 37,2 tomarán la posición sociológica 3- y su diámetro inicial será un valor aleatorio con media 3,3 y desviación 4,2. Los menores de 77,3 tendrán posición sociológica 2 y su DN inicial es un rango de media 4,2 y desviación 5,1 y finalmente los de valor aleatorio entre 77,3 y 100 serán catalogados como dominantes, posición sociológica 1 y su DN se calcula como un valor aleatorio uniforme con media 5,2 y 7,4

La mortalidad se calculó como el 2,5% de los árboles con posición sociológica 4, determinado a partir del conocimiento empírico de expertos y de acuerdo con la zona.

A partir de las coordenadas (x, y) se generaron 2 matrices de 1089x8, la primera con los correspondientes vecinos de cada árbol y la segunda con las distancias a cada vecino.

A partir de las matrices anteriores se calculó el Índice de Competencia de Hegyi para cada árbol y se completó el conjunto de datos para la simulación.

Con la ayuda del modelo de crecimiento de árbol individual, generado con el entrenamiento de la RNA sensible al número de vecinos, se realizó la simulación.

Se adiciona para la simulación el cálculo de: área de la sección de cada árbol a la altura del pecho a partir del Diámetro Normal dado en metros (DN/100) – A (Ecuación 3.10), el área basal de la parcela – G (Ecuación 3.11, donde  $n$  es el número de árboles de la parcela), número de árboles por hectárea -  $N$  (Ecuación 3.12, donde  $a_p$  es el área de la parcela), diámetro medio cuadrático –  $d$  (Ecuación 3.13), y el Índice de Densidad del Rodal –  $IDR$  (Ecuación 3.14):

$$\text{Área de sección} \quad A = \pi * \left( \frac{DN}{100*2} \right)^2 \quad (3.10)$$

$$\text{área basal} \quad G = \sum_{i=1}^n A \quad (3.11)$$

$$\text{número de árboles} \quad N = \frac{10000}{a_p} \sum_{i=1}^n 1 \quad (3.12)$$

$$\text{diámetro medio cuadrático} \quad d = \sqrt{\frac{40000*G}{\pi*N}} \quad (3.13)$$

$$\text{Índice de Densidad del Rodal} \quad IDR = N * \left( \frac{d}{25} \right)^{1,989} \quad (3.14)$$

A partir de los diámetros de los árboles cortados, se calcula para cada uno de ellos la altura, y el volumen de acuerdo al modelo planteado por Schumacher & Hall (1933) con los coeficientes obtenidos para los rodales ubicados en Armero Guayabal (Ramos Molina & Niño López, 2017) (Ecuaciones (3.15) y (3.16)). El volumen es acumulado y se calcula el volumen total tras la última cosecha. El volumen final acumulado se tomará como la función objetivo, es decir que la solución que obtenga el mayor volumen al final de la simulación se tomará como la solución óptima o que más se acerque a la óptima.

En la función costo, la altura de los árboles se calculó por regresión con la ecuación logarítmica (5.6):

$$H = \beta_1 * \ln(DN) - \beta_2 \quad (3.15)$$

donde los valores de los coeficientes son  $\beta_1 = 8,8048$  y  $\beta_2 = 11,816$ .

El volumen se calculó con la ecuación 5.7 (Ramos Molina & Niño López, 2017):

$$v = \beta_1 * d^{\beta_2} * H^{\beta_3} - e \quad (3.16)$$

donde los valores de los coeficientes son  $\beta_1 = 0.000098$ ,  $\beta_2 = 1.813270$  y  $\beta_3 = 0.779365$

El resultado del trabajo de la red de autómatas celulares simula el comportamiento del rodal, a partir del modelo de árbol individual.

### 3.3 Fase 3. Mejoramiento política de manejo de raleo (AG):

#### 3.3.1 Implementación del Algoritmo Genético

Como herramienta del Aprendizaje Automático (Machine Learning) para la optimización de los procesos de raleo se escogió el Algoritmo Genético, con el cual se determina el número de raleos a realizar y el porcentaje de árboles a cortar (intensidad) en cada raleo. La evaluación de la función objetivo (o función costo) se realiza simulando el crecimiento de los árboles con la Red de Autómatas Celulares donde se incluyen los tiempos de raleos y su intensidad.

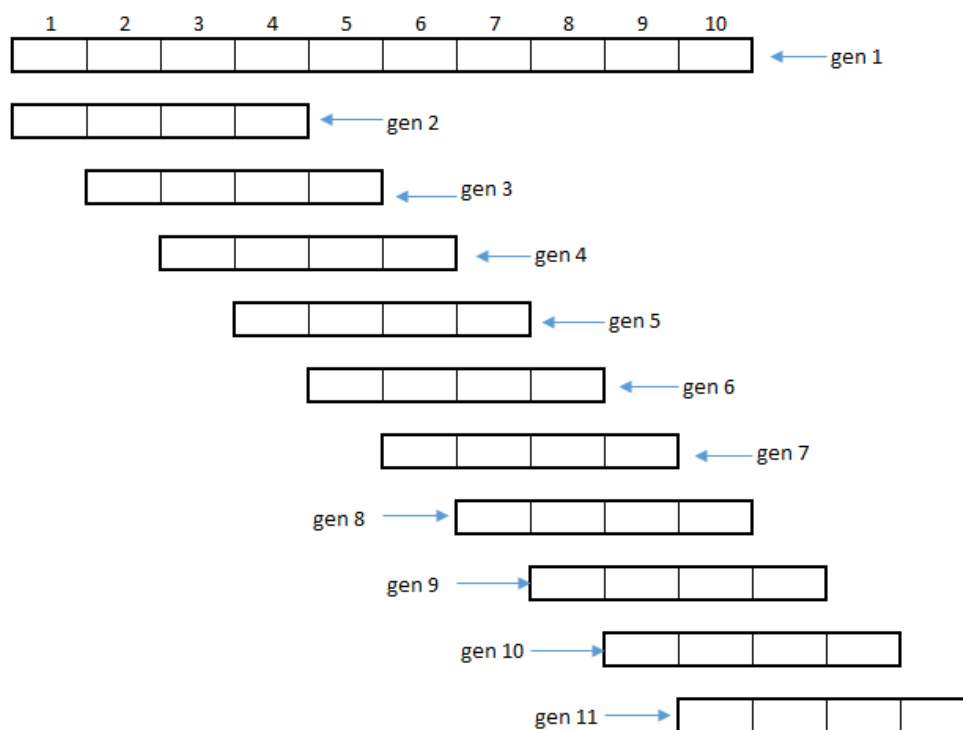


Figura 30: Estructura del cromosoma

Fuente: Autor

Para aprovechamiento (cosecha) final a los 12 años el cromosoma tendrá la siguiente forma: el primer gen de 10 bits y los genes del 2 al 11 de 4 bits para un total de 50 bits por cromosoma.

Cada cromosoma es representado por un vector binario. El tamaño del cromosoma se determina de acuerdo al año de cosecha de tal manera para un aprovechamiento a los  $N$  años, el cromosoma tendrá  $N-1$  genes: El primer gen es un subvector de  $N-2$  bit y representa el Año de raleo y los demás genes ( $N-2$ ) representan la intensidad de raleo donde cada gen tiene un tamaño de 4 bits. En el primer gen un uno en el bit  $i$  significa que en el año  $i$  se realizará el raleo; por cada bit del primer gen hay un subarreglo de 4 bits que representará en forma porcentual la intensidad del raleo y cuyo valor numérico se multiplica por 5: Es decir que la intensidad del raleo puede ir porcentualmente desde 0% en múltiplos de 5, hasta el 80%

La generación inicial está compuesta por 50 individuos sobre los cuales se realizó una selección elitista, cruce entre individuos y mutación aleatoria.

El Algoritmo Genético se repitió por 60 veces con un criterio de parada adicional cuando no se consigue mejorar los valores de volumen.

El Anexo 2 contiene el programa (script) que maneja el algoritmo genético.

Las condiciones iniciales del algoritmo genético son:

Población Inicial  $N_p = 50$  individuos. Cada individuo está compuesto por un vector binario cuya longitud  $L_v$ , depende de la Edad de Cosecha  $E_c$  y la codificación de la Intensidad de raleo  $I_{ntsd}$ , de la siguiente forma:  $L_v = E_c - 2 + (E_c - 2) * I_{ntsd}$

Para este caso la intensidad del raleo se codifica con 4 bits y su valor decimal se multiplica por 5 para una intensidad de raleo entre el 0 y el 80 por ciento.

Para la evaluación de la función objetivo se simula el crecimiento de un rodal de una hectárea por cada individuo de la población, calculando el volumen de madera que se recoge en cada raleo y la cosecha final. Los datos iniciales para la simulación y evaluación de la función objetivo son: Número de árboles en la hectárea:  $N=1089$ , sembrados a una distancia de 3 metros entre sí; Diámetros Iniciales DN: vector con 1089 valores iniciales; vector binario de 1089 elementos con uno para los árboles en pie y 0 para los árboles eliminados ya sea por raleo o por mortalidad.

### 3.3.2 Cálculo de biomasa y captura de carbono

La biomasa total de ese año y su respectiva captura de carbono, tienen que ser calculadas periódicamente (Martins Silva et al., 2019; Obando Bonilla, 2004).

El peso o estimación equivalente de la materia orgánica que existe en un determinado ecosistema forestal por encima y por debajo del suelo se denomina biomasa forestal. Normalmente se cuantifica en toneladas por hectárea de peso verde o seco. La biomasa del árbol total se compone de la biomasa subterránea y de la biomasa aérea. La biomasa

subterránea está formada por las raíces del árbol y la biomasa aérea está formada por la biomasa del tallo junto con la biomasa de ramas, hojas, flores y frutos.

Para calcular la biomasa total se utilizan dos relaciones: Factor de expansión de la biomasa (FEB) (Ecuación (3.17)):

$$FEB = \frac{\text{Biomasa aérea}}{\text{Biomasa del tronco}} \quad (3.17)$$

Y la relación R entre la biomasa del suelo y la biomasa aérea (Ecuación (3.18)):

$$R = \frac{\text{Biomasa terrestre}}{\text{Biomasa aérea}} \quad (3.18)$$

Para el cálculo de la biomasa aérea en plantaciones de bosque seco tropical en el departamento del Tolima, se utiliza la siguiente ecuación (Rodríguez Santos, 2013) (Ecuación (3.19)):

$$\text{Log}_{10}(B) = a_1 + a_2 \text{Log}_{10}(DAP) \quad (3.19)$$

Junto con los siguientes parámetros  $a_1 = -1.988 \pm 0.192$ ,  $a_2 = 2.993 \pm 0.138$ . Coeficiente de determinación  $R^2 = 0.97$  y  $CME = 0.070$

Igualmente se tiene para esta región la siguiente distribución (Obando Bonilla, 2004):

Tabla 7. Porcentaje de carbono promedio por componente y porcentaje que tiene el componente en la biomasa total en árboles de *Gmelina arborea* Roxb

COMPONENTE	% CARBONO	% BIOMASA
Tallo	43,13	63,87
Ramas	41,39	16,35
Raíz Delgada	41,75	4,38
Raíz Gruesa	42,55	12,43
Hojas	36,46	3,27
<b>PROMEDIO</b>	<b>41,39</b>	<b>100</b>

Para el cálculo del carbono capturado o almacenado se tiene la siguiente relación para la especie (Ecuación (3.20)):

$$CA = B \cdot FC \quad (44/12) \quad (3.20)$$

donde:  $CA$  es el  $CO_2$  almacenado,  $B$  es la biomasa (subterránea, aérea o total) del árbol y  $FC$  es la fracción de carbono para la especie calculado en 42,497.

Como resultado del algoritmo genético se acerca el valor del volumen obtenido al posible valor máximo e volumen.

Como síntesis del capítulo, se quiere mostrar que la ventaja de la metodología propuesta, está en el uso del algoritmo genético como una herramienta de optimización que permitirá planificar con mayor precisión el componente esencial en el manejo de la silvicultura, como lo es el raleo. En la actualidad, la generalidad de modelos implementados para el sector forestal, no incluyen las herramientas computacionales de la Inteligencia Computacional con propósitos de optimización en el manejo de las plantaciones y la metodología propuesta sería una de las primeras en mostrar su eficiencia

## 4 EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS

Los árboles seleccionados y los valores obtenidos de los índices de competencia por parcela se muestran en el anexo, así como los datos para su obtención. Los estadísticos que respaldan los índices seleccionados se muestran a continuación:

### 4.1 Estudio de densidad de la especie seleccionada

Tomando un total de 10 parcelas que se consideran se encuentran con densidad de autoraleo, se calcula la línea máxima de densidad para la especie melina, aplicando a este grupo de parcelas, a partir de las relaciones :  $\text{Log}_{10} N=Y$  y  $\text{Log}_{10} Dg=X$  para obtener el modelo lineal  $Y= a + b (X)$ , se obtuvieron las siguientes estimaciones en el paquete estadístico The SAS System: intercepto  $a= 5,1287$  y la pendiente  $b= -1,8008$ , confirmando que la pendiente es un parámetro específico para cada especie y que debe ser estimado a partir de los datos de estudio.

Tabla 8. Parcelas que determinan la línea de máxima densidad, con sus respectivos índices de densidad de rodal - IDR y estimación del IDR<sub>Máx</sub>

Parcela	Dg (cm)	Nº Árboles/Ha	Log <sub>10</sub> (Dg)	Log <sub>10</sub> (N/Ha)	IDR	IDR <sub>Máx</sub>
1	22,2	563	1,35	2,75	455	572
2	21,2	650	1,33	2,81	485	
3	21,5	688	1,33	2,84	524	
4	14,5	1295	1,16	3,11	488	
5	18,3	963	1,26	2,98	550	
6	17,2	1000	1,24	3,00	514	
7	16,8	1000	1,23	3,00	490	
8	17,3	950	1,24	2,98	488	
9	15,8	1088	1,20	3,04	479	
10	18,5	950	1,27	2,98	553	

Igualmente se halló la magnitud máxima del intercepto para estimar  $a_{\max}$ . Una de las formas para obtener este parámetro es incrementar el intercepto  $a$  en 1,96 desviaciones estándar del error del modelo (Wittwer et al., 1998). Es decir,  $a_{\max} = a + (1,96 * \text{Root MSE})$ , obteniendo como resultado  $a_{\max} = 5,2652$ .

A partir de 10 parcelas con mayor densidad, y que se consideraron en estado de autoraleo, se calculó el  $\text{IDR}_{\max}$  para ser utilizado para la construcción de las zonas de densidad.

#### 4.1.1 Zonas de densidad

La determinación de las zonas de densidad a partir del  $\text{IDR}_{\max}$  permite definir el número de árboles necesarios para obtener un diámetro requerido y se utiliza para cuantificar el porcentaje de raleo en la planificación silvícola. Igualmente, el  $\text{IDR}_{\max}$  hace parte de las restricciones del modelo de crecimiento propuesto.

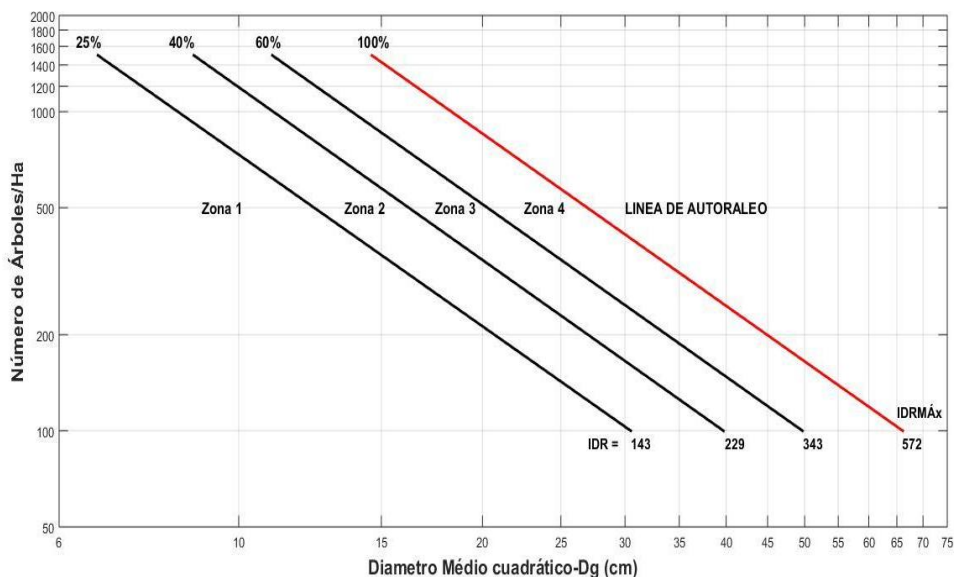


Figura 31: Diagrama general de manejo de la densidad para plantaciones de *Gmelina arborea* Roxb en el Departamento del Tolima, con las respectivas zonas de densidad.

Fuente: Autor.

Los límites de las zonas fueron calculados a partir del  $\text{IDR}_{\max}$  encontrado (572), este índice hace parte de las restricciones que debe manejar la Red de Autómatas Celulares.

## 4.2 Modelo empírico de crecimiento con índice de competencia

Se modeló el crecimiento con las ecuaciones alométricas de árbol individual, que permitirán comparar los resultados con los obtenidos con la Red Neuronal Artificial.

### 4.2.1 Selección del índice de competencia

Para la selección de los mejores índices de competencia, se utilizaron las ecuaciones 3.1, 3.2 y 3.3 donde cada índice se tomó como variable dependiente para modelar el delta de crecimiento. Se consideraron los estadísticos: coeficiente de determinación ( $R^2$ ) y la raíz del error medio cuadrático (*REMC*), para su clasificación.

Los modelos, donde se considera el índice de competencia como única variable, no arrojan resultados satisfactorios. En general se obtuvieron los mejores resultados utilizando los modelos lineal y exponencial, como se muestra en la Tabla 9. Sin embargo se corresponde a las obtenidas en la literatura (Castagneri et al., 2008; Crecente Campo et al., 2007).

Tabla 9: : Estadístico de ajuste del mejor modelo (lineal, potencial o exponencial) para las variables independiente "crecimiento en diámetro y altura", e índices dependientes de la distancia de los árboles suprimidos, codominantes y dominantes

<b>Estrato</b>	<b>Delta</b>	<b>Índice de Competencia</b>	<b>Modelo</b>	<b>R<sup>2</sup></b>	<b>REMC</b>
Suprimidos	Delta de Altura	Daniels	Lineal	0,2613	0,2814
		Steabler	Lineal	0,3471	0,3374
	Delta de Diámetro	Hegyi	Potencial	0,4072	0,3865
		Steabler	Lineal	0,3964	0,3491
Codominantes	Delta de Altura	Pukkala	Lineal	0,2994	0,279
		Daniels	Lineal	0,2815	0,3014
	Delta de Diámetro	Hegyi	Lineal	0,3314	0,3287
		Martin-Ek	Exponencial	0,2136	0,1986
Dominantes	Delta de Altura	CCS	Potencial	0,3021	0,2689
		Hegyi	Lineal	0,2681	0,2813
	Delta de Diámetro	Steabler	Lineal	0,3497	0,3662
		Daniels	Exponencial	0,2316	0,2417

En la Tabla 8 se incluyen únicamente los índices dependientes de la distancia que arrojaron los mejores resultados tanto para el delta de altura como para el delta de diámetro, para cada una de las categorías que se trabajaron.

Los índices dependientes de la distancia presentan resultados ligeramente mejores para los deltas de Diámetro y altura que los que índices independientes de la distancia. No se obtuvieron diferencias significativas entre los índices dependientes e independientes de la distancia. Se esperaba un mejor comportamiento de aquellos modelos que incorporan índices dependientes de la distancia frente a aquellos de mayor simplicidad basados únicamente en valores medios por parcela y/o funciones simples de dimensiones de los individuos. Sin embargo, la mayoría de las comparaciones realizadas entre modelos dependientes e independientes de la distancia no reflejan las diferencias esperadas.

El índice más consistente resulto ser el de Hegyi, seguido por el de Daniels.

#### 4.2.2 Modelo de Validación:

Para la validación de los resultados de la Red Neuronal Artificial, se utilizaron los modelos empíricos de árbol individual de las ecuaciones 3.4, 3.5, 3.6. En la siguiente tabla se presentan los resultados obtenidos de los modelos estadísticos (ecuaciones 3.4, 3.5, 3.6)

Tabla 10: Resultado del modelos 3.4,3.5,3.6

Equation	Observations	Parameters	Error DF	ECM	R <sup>2</sup>	Adjusted R <sup>2</sup>
(3.4)	2649	6	2643	0.9472	0.4553	0.4542
(3.5)	2649	7	2642	0.9223	0.4698	0.4698
(3.6)	2649	7	2642	0.9401	0.4595	0.4583

Donde R<sup>2</sup> es el coeficiente de determinación del modelo y EMC es el error medio cuadrático del modelo.

Los resultados de los modelos, aunque incluyen el Índice de Competencia, no son satisfactorios para la simulación requerida, sin embargo, permiten seleccionar la ecuación que mejor modela el crecimiento y es el seleccionado para validar los resultados de la Red Neuronal.

#### 4.3 Modelo de crecimiento a partir de una Red Neuronal Artificial

Para la comparación entre modelos, el software MatLab incluye el error medio cuadrático (ECM) y el valor de regresión R (correlación entre lo simulado y el objetivo que se presentan a continuación:

- **Resultados de Red neuronal de una capa oculta con cinco entradas**

La tabla 14 muestra el comportamiento de las épocas, el tiempo de entrenamiento, el desempeño obtenido y el comportamiento de algunos parámetros (gradiente y mu).

Tabla 11. Resultado del proceso de entrenamiento de la red neuronal de una capa oculta con cinco entradas

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	14	1000
Elapsed Time	-	00:00:00	-
Performance	1.26e+03	0.825	0
Gradient	3.04e+03	0.859	1e-07
Mu	0.001	0.001	1e+10
Validation Check	0	6	6

Tabla 12: Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con cinco entradas

	Observaciones	ECM	R
<b>Training</b>	1885	0.8725	0.8714
<b>Validation</b>	404	0.9816	0.8939
<b>Test</b>	404	1.1579	0.8859

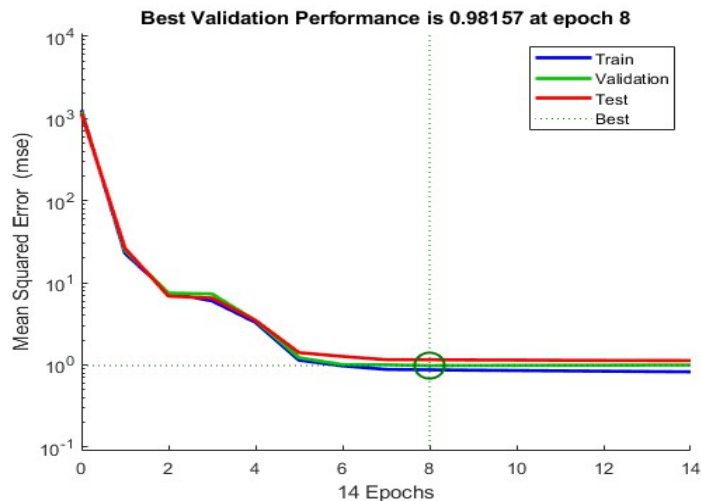


Figura 32: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con cinco entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos

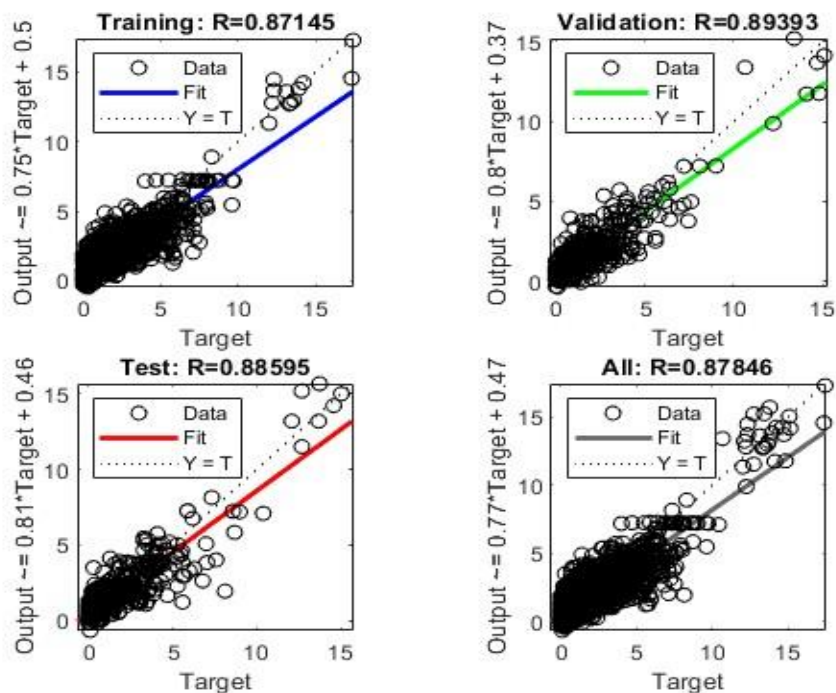


Figura 33: Valores de R, correlación entre los datos de simulación y los datos objetivos (red neuronal de una capa oculta con cinco entradas)

- **Resultados de Red neuronal de una capa oculta con siete entradas**

- 

La tabla 15 muestra el comportamiento de las épocas, el tiempo de entrenamiento, el desempeño obtenido y el comportamiento de algunos parámetros (gradiente y mu).

Tabla 13: Resultado del proceso de entrenamiento de la red neuronal de una capa oculta con siete entradas

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	15	1000
Elapsed Time	-	00:00:01	-
Performance	2.13e+03	0.641	0
Gradient	4.43e+03	0.642	1e-07
Mu	0.001	0.001	1e+10
Validation Check	0	6	6

- Tabla 14. Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con siete entradas

	Observaciones	ECM	R
<b>Training</b>	1885	0.7055	0.9083
<b>Validation</b>	404	0.1319	0.8457
<b>Test</b>	404	1.2043	0.8603




Figura 34: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con siete entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos

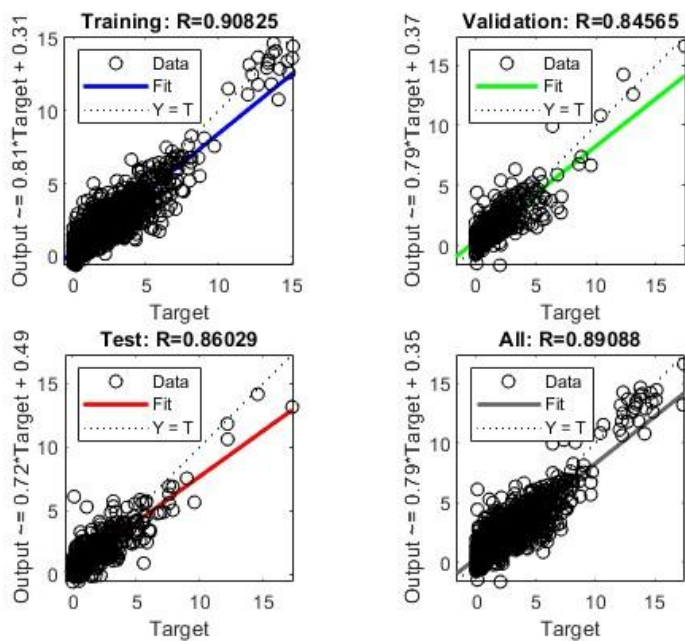


Figura 35: . Valores de R, correlación entre los datos de simulación y los datos objetivos para los tres distintos datos de entrenamiento y el promedio de estos (red neuronal de una capa oculta con siete entradas)

### Resultados de Red neuronal de una capa oculta con ocho entradas

La tabla 17 muestra el comportamiento de las épocas, el tiempo de entrenamiento, el desempeño obtenido y el comportamiento de algunos parámetros (gradiente y mu).

Tabla 15. Parámetros del proceso de entrenamiento de la red neuronal de una capa oculta con ocho entradas

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	14	1000
Elapsed Time	-	00:00:02	-
Performance	1.5e+03	0.652	0
Gradient	3.81e+03	0.261	1e-07
Mu	0.001	0.01	1e+10
Validation Check	0	6	6

Tabla 16. Estadísticos obtenidos por el modelo de red neuronal de una capa oculta con ocho entradas

	Observaciones	ECM	R
<b>Training</b>	1885	0.6775	0.9144
<b>Validation</b>	404	0.5068	0.8031
<b>Test</b>	404	1.2389	0.8367




Figura 36: Comportamiento del error durante el entrenamiento de la red neuronal de una capa oculta con ocho entradas, a partir de los datos para entrenamiento, validación y test. Se muestra el ciclo (época) en que se logran los errores mínimos admitidos

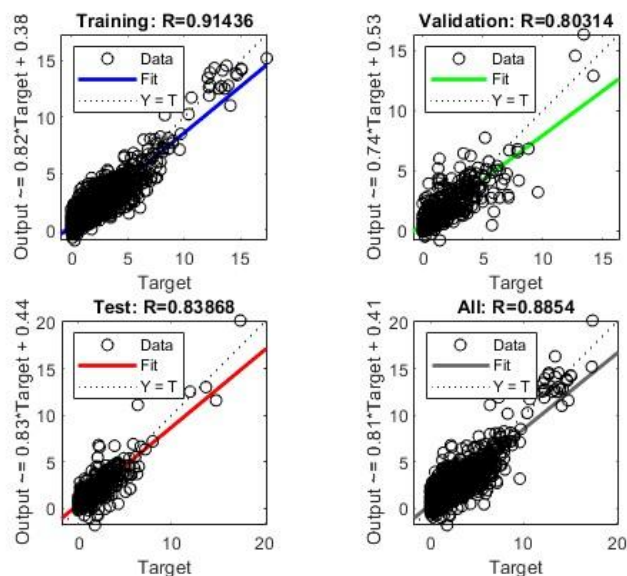


Figura 37: Valores de R, correlación entre los datos de simulación y los datos objetivos para los tres distintos datos de entrenamiento y el promedio de estos (red neuronal de una capa oculta con ocho entradas)

Revisando las tablas 13, 15 y 17, se observa cómo el algoritmo de entrenamiento de manera rápida consigue llegar a los errores permitidos sin que se tenga que cumplir con el número de ciclos establecido (épocas), mostrando la eficiencia del algoritmo de entrenamiento de retro propagación del error Levenberg-Marquardt (Tudoroiu et al., 2009).

### Comparación error cuadrático medio

Tabla 17. Resultados del error medio cuadrático (ECM) para los datos de entrenamiento, validación y test.

ECM			
Tipo de red	Entrenamiento	Validación	Test
Red neuronal de una sola capa oculta – 5 entradas sin competencia	0.8725	0.9816	1.1579
Red neuronal de una sola capa oculta – 7 entradas con competencia	0.7055	1.1319	1.2043
Red neuronal de una sola capa oculta – 8 entradas con competencia	0.6775	1.5068	1.2389

Valores de Regresión R que miden las salidas de correlación entre los datos de entrada y la salida objetivo que incluye la validación y el test. Un valor R cercano a 1 significa una estrecha relación, cercano a 0 una relación aleatoria.

Tabla 18. Resultado de la eficiencia (parámetro R) de los modelos con los datos de entrenamiento, validación y test.

R				
Tipo de red	Entrenamiento	Validación	Test	Promedio
Red neuronal de una sola capa oculta – 5 entradas sin competencia	0.87145	0.89393	0.88595	0.87846
Red neuronal de una sola capa oculta – 7 entradas con competencia	0.90825	0.84565	0.86029	0.89088
Red neuronal de una sola capa oculta – 8 entradas con competencia	0.91436	0.80314	0.83868	0.8854

#### 4.4 Resultados de la simulación del rodal con Autómatas Celulares

Para la simulación de la plantación con ayuda de un autómatas celular, se incluyó el cálculo del IDR máximo, de la sección 4.1, que hace parte de la principal restricción del modelo de crecimiento del rodal. El  $IDR_{max}$  representa la máxima densidad que puede alcanzar el rodal, después de la cual, por competencia y recursos, no hay crecimiento de sus individuos. El valor obtenido para el  $IDR_{max} = 572$ .

De acuerdo con los expertos, el tiempo de cosecha promedio de los rodales de *Gmelina arborea Roxb.* en plantaciones comerciales es de 12 años, por lo tanto se hizo una simulación de crecimiento del rodal para 12 años, teniendo en cuenta raleos a los dos y a los cinco años.

Para efectos de la simulación, se crearon las siguientes tablas:

Tabla 19. Tamaño de las matrices y vectores utilizados en la simulación del autómata celular

Nombre de la tabla	Dimensiones
disvecino	1089x8
disxy	1089x1089
DN	1x1089
DNvecino	1089x8
IC	1x1089
IS	22.1000
Numvcn	1x1089
Posición	1x1089
ran	1x1089
vecino	1089x8
vivos	1x1089
x	1x1089
y	1x1089

Donde:

- disvec: corresponde a la distancia que tiene el árbol con sus vecinos, de acuerdo a la vecindad de Moore.
- disxy: corresponde a distancia de cada árbol a todos los demás árboles de la parcela.
- DN: corresponde al diámetro inicial de los árboles.
- DNvecino: corresponde al diámetro normal de los vecinos, de acuerdo a la vecindad de Moore.
- IC: corresponde al Índice de competencia de cada uno de los árboles de la parcela.
- IS: es un valor calculado para toda la simulación.
- Numvcn: es el número de vecinos de cada árbol.
- Posición: es la posición sociológica que se le calculó a cada árbol.
- Vecino: es una tabla de ayuda para hallar el IC.
- Vivos: es una tabla con una variable binaria, de acuerdo con la posición de los árboles, donde 1 es vivos y 0 no.
- x , y: corresponde a la posición en la grilla.

Por lo que, el comportamiento del diámetro medio cuadrático (Figura 39) y el volumen por hectárea (Figura 40) vendría a ser:

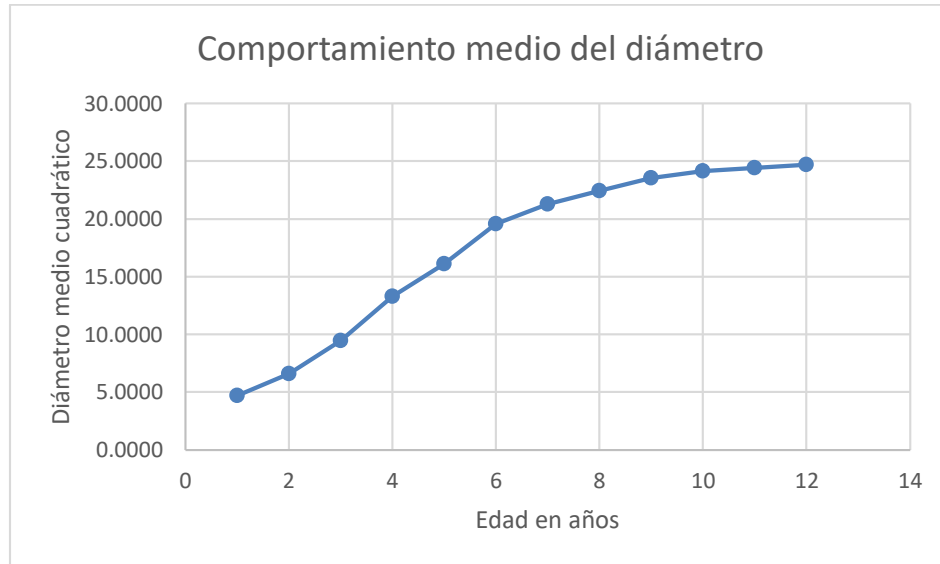


Figura 38: Comportamiento medio del diámetro

Fuente: autor




Figura 39: Volumen representado en metros cúbicos por hectárea

Fuente: autor

A partir del diámetro y el cálculo del tamaño de la copa, se dibuja aproximadamente la visión aérea de la cuarta parte de una hectárea (Figura 28).




Figura 40: Simulación de una parcela en 2 dimensiones. Representación de la red de autómatas celulares, donde se utiliza la vecindad de Moore.

Fuente: Autor

Tabla 20. Resultado de la simulación del rodal a partir del crecimiento de cada uno de los árboles de la parcela

Edad	G	N	d	IDR	V
1	1,8214	1058	4,6818	37,7951	6,4323
2	3,5888	1058	6,5719	74,1937	15,1272
3	7,4069	1058	9,4413	152,5169	36,7594
4	12,4554	899	13,2817	255,5116	70,2752
5	18,2713	899	16,0865	374,0306	110,4749
6	14,8875	494	19,5885	304,1003	95,5706
7	17,5289	494	21,2554	357,7343	114,9021
8	18,5667	469	22,4510	378,6848	123,2018
9	17,3360	399	23,5203	353,4036	116,1075
10	18,2749	399	24,1488	372,4345	122,9762
11	18,6980	399	24,4268	381,0582	126,0786
12	19,1260	399	24,7047	389,6819	129,1810

## 4.5 Optimización por Algoritmos Genéticos

Debido a que el algoritmo utiliza valores aleatorios al momento de crear la población, este se ejecutó varias veces, obteniendo siempre resultados diferentes. Se cambió, primero, por una población más pequeña de 30 individuos debido a que el algoritmo consume bastante tiempo de máquina. Luego, se ejecutaron para 50 individuos. Y, finalmente, para 100 individuos.

Dado que el mejor resultado se obtuvo para 50 individuos. Los mejores valores obtenidos se muestran en la Tabla 23.

Tabla 21: Mejor resultado obtenido en el AG

No.	Año de raleo	Porcentaje raleo	Arboles a cortar
1	3	15	159
2	5	45	405
3	7	5	25
4	8	15	70
5	12	100	399

Volumen raleos: 59,584 m<sup>3</sup>

Volumen final =188,765

Diámetro medio cuadrático final:  $d = 24.7047$

Vector de 50 elementos con los datos del mejor individuo, se resalta con rojo los valores que empleó el algoritmo, por ejemplo, en el gen 1, significa que hay raleo en el año 3 y la intensidad del raleo, se encuentra en el gen 4, donde el número binario 3 es multiplicado por 5 para indicar que el raleo tiene una intensidad del 15 por ciento. Luego en el gen 1, en la posición 5, vuelve a haber un 1, lo que significa que en el año 5 se volverá a hacer raleo, y la intensidad está en el número binario 1001 del gen 6, es decir 9 multiplicado por 5, para una intensidad del 45 por ciento. De igual manera, en los genes 7 y 8, vuelve a haber 1, que corresponderán en el gen 8 al 5 por ciento, y en el gen 9 al 15 por ciento (Ver Tabla 21).

11 Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
 0 la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
 Inteligencia Computacional

Tabla 22: Representación binaria del cromosoma.

	Gen 1										
Cromosoma	0	0	1	0	1	0	1	1	0	0	
índice	1	2	3	4	5	6	7	8	9	10	
Gen 2				Gen 3				Gen 4			
0	0	1	1	1	0	0	1	0	0	1	1
11	12	13	14	15	16	17	18	19	20	21	22
Gen 5				Gen 6				Gen 7			
1	0	0	0	1	0	0	1	1	0	1	1
23	24	25	26	27	28	29	30	31	32	33	34
Gen 8				Gen 9				Gen 10			
0	0	0	1	0	0	1	1	1	0	0	1
35	36	37	38	39	40	41	42	43	44	45	46
Gen 11											
0	1	1	0								
47	48	49	50								



Figura 41 : representación decimal del cromosoma

Al algoritmo se le adicionó una simulación gráfica en 2D de aproximadamente una cuarta parte de la parcela, donde se muestra la ubicación del árbol en un año y de la cosecha final (ver Figura 41).

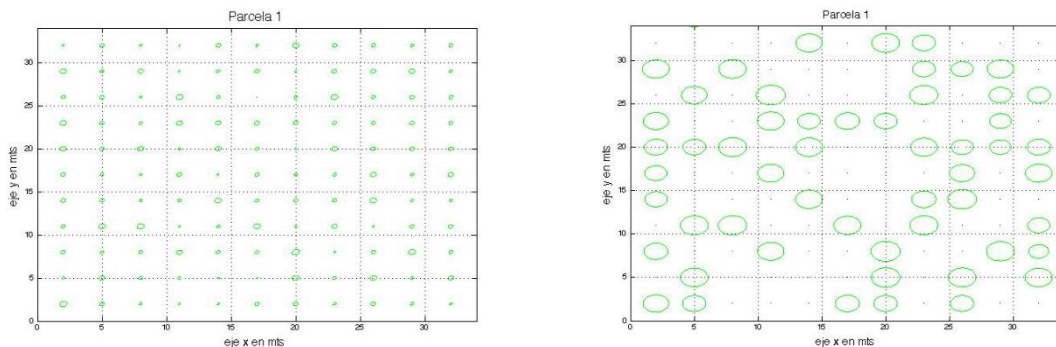


Figura 42: Simulación 2D de los diámetros de los árboles de un año (Izquierda) – Simulación 2D de los diámetros de los árboles a los 12 años, antes de la cosecha final (Derecha). Parcela de 35x35 mts

El script '*Poblacn=Poblacion(Pb,anios);*' genera una matriz '*Poblacn*' con un archivo binario de 50x50, de manera aleatoria. La función *fcost* entrega fila por fila a la variable *pob*, es decir, cada elemento de la población es entregado a la función *raleos*, la función *raleos* devuelve el volumen final a los años solicitados, y la función *fcost* guarda el volumen final de cada cromosoma de la población.

El script '*PobSelec1 = Seleccion(Poblacn,fcosto);*' guarda los 25 mejores cromosomas, y en *his pobla* se guarda el mejor de todos. Esta siguiente instrucción guarda el mejor de todos '*HistPoblac(k1,:)=PobSelec1(1,:);*' con ayuda de la función *torneo* compara aleatoriamente dos individuos de la población y guarda en '*PobSelec2= Torneo(Poblacn,fcosto)*' los 25 mejores. Se ordenan nuevamente y en el *HistFcosto* se guarda el volumen del mejor elemento de la población.

A cada individuo de la nueva población '*PobNew=cruce(PobSelec1,PobSelec2,anios);*' se le entrega un valor aleatorio y a aquellos cuyos valor sea menor a 0.01 se les aplica una mutación a cada gen, '*Poblacn=mutacion(PobNew,anios); end*' que genera el cruce entre la población seleccionada 1 y 2 para crear la nueva población para el siguiente ciclo. Este proceso se realiza 60 veces

La función *fenotipo* escoge del *HistFcosto*, al individuo que obtuvo el mayor volumen, para volverlo a simular y entregar como respuesta los años de raleo, el porcentaje de raleo, los árboles a cortar en cada raleo y la cosecha final, al igual que el diámetro medio cuadrático final de la hectárea.

Este proceso se realizó en el software MatLab y los archivos de todas las variables se guardan en un archivo de extensión *.mat* (workspace).

## 4.6 Validación del modelo

Para contrastar los resultados del modelo se corrieron los datos de las mediciones en el software SIMFOR- Simulador de Crecimiento de Plantaciones Forestales versión 1.2.

11 Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
 2 la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
 Inteligencia Computacional

---

El Simulador –SimFor fue desarrollado por el Instituto de Informática de la Facultad de Ciencias de la Ingeniería de la Universidad Austral de Chile para la Corporación Nacional de Investigación y Fomento Forestal CONIF @ de Colombia, año 2013. Los Autores Líderes del Proyecto son los Ingenieros de la Universidad del Tolima Ana Milena López, Alonso Barrios Trilleras, el Ingeniero de CONIF Víctor Manuel Nieto, y el Asesor Científico del proyecto es el Ingeniero Guillermo Trincado.

Los resultados de la simulación se encuentran en la tabla adjunta:

Tabla 23: Simulación interactiva

Zona	Especie	Manejo	E	N	Hd	Hm	G	dg	dm	dd	V	IDR
Región Andina	Gmelina arborea		1	1058	6,97	3,84	1,82	4,68	3,92	9,29	3,92	71,91
Región Andina	Gmelina arborea		2	1049,24	12,23	9,6	9,24	10,59	10,14	15,38	35,8	264,21
Región Andina	Gmelina arborea		3	1040,56	15,38	13,05	16,47	14,19	13,78	19,41	83,25	419,49
Región Andina	Gmelina arborea	Post-Raleo	3	884,48	15,38	13,21	14,91	14,65	14,24	19,41	75,99	375,13
Región Andina	Gmelina arborea		4	877,16	17,52	15,49	20,16	17,11	16,7	22,49	118,56	477,18
Región Andina	Gmelina arborea		5	869,9	19,08	17,13	24,31	18,86	18,44	24,8	156,98	553,57
Región Andina	Gmelina arborea	Post-Raleo	5	478,43	19,08	17,6	16,24	20,79	20,38	24,8	106,69	355,84
Región Andina	Gmelina arborea		6	474,47	20,29	18,85	18,46	22,25	21,84	27,47	126,93	393,66
Región Andina	Gmelina arborea		7	470,54	21,25	19,83	20,26	23,41	22,99	29,17	146,07	423,53
Región Andina	Gmelina arborea	Post-Raleo	7	447,02	21,25	19,88	19,65	23,66	23,24	29,17	141,29	409,13
Región Andina	Gmelina arborea		8	443,32	22,05	20,69	21,1	24,61	24,19	30,79	157,71	432,41
Región Andina	Gmelina arborea	Post-Raleo	8	376,85	22,05	20,8	18,89	25,26	24,84	30,79	141,48	383,24
Región Andina	Gmelina arborea		9	373,73	22,72	21,48	19,98	26,09	25,66	32,43	153,45	400,18
Región Andina	Gmelina arborea		10	370,64	23,29	22,05	20,9	26,8	26,36	33,58	164,54	414,28
Región Andina	Gmelina arborea		11	367,57	23,79	22,54	21,69	27,41	26,96	34,61	174,35	426,16
Región Andina	Gmelina arborea		12	364,53	24,22	22,98	22,38	<b>27,96</b>	27,5	35,53	<b>183,05</b>	436,25

Se simuló el crecimiento en los años propuestos y se obtuvo para el volumen el valor de 183.05 metros cúbicos, con un diámetro medio cuadrático de 27.96 centímetros.

El volumen del modelo propuesto en este proyecto es de 188.77 metros cúbicos, y el diámetro medio calculado es de 24.7 cm.

El simulador SimFor cuenta con los parámetros de la especie para la región, pero no se actualizan después del Raleo. Los autores del modelo están trabajando en el cambio de parámetros como respuesta al raleo, para lo cual tienen un ensayo con este propósito.

#### 4.7 Resultados del Cálculo de biomasa y Captura de carbono

Para el cálculo de la biomasa se tuvo en cuenta el trabajo realizado por (Obando Bonilla, 2004) sobre la misma especie en el Norte del Tolima.

Tabla 24. Cálculo del factor de biomasa

	<b>FC</b>	<b>Biomasa</b>	<b>Promedio</b>	<b>Raíz</b>	<b>Aérea</b>
<b>Tallo</b>	43,13	63,87	2754,7131		63,87
<b>Ramas</b>	41,39	16,35	676,7265		16,35
<b>Raíz delgada</b>	41,75	4,38	182,865	4,38	
<b>Raíz gruesa</b>	42,55	12,43	528,8965	12,43	
<b>Hojas</b>	36,46	3,27	119,2242		3,27
	41,056	100,3	4262,4253	16,81	83,49
		FC =	42,497	R =	0,20134148

Tabla 25. Cálculo de carbono capturado por hectárea

<b>Edad</b>	<b>G</b>	<b>N</b>	<b>d</b>	<b>IDR</b>	<b>V</b>	<b>BT</b>	<b>CO2_ha</b>	<b>CO2_acum</b>
1	1,8214	1058	4,6818	37,7951	6,4323	1326,48	2,0669	2,0669
2	3,5888	1058	6,5719	74,1937	15,1272	3660,13	5,7033	7,7702
3	7,4069	1058	9,4413	152,5169	36,7594	10824,74	16,8674	24,6376
4	12,4554	899	13,2817	255,5116	70,2752	25546,27	39,8068	64,4444

11 Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
 4 la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
 Inteligencia Computacional

5	18,2713	899	16,0865	374,0306	110,4749	45327,60	70,6305	135,0749
6	14,8875	494	19,5885	304,1003	95,5706	44911,36	69,9819	205,0569
7	17,5289	494	21,2554	357,7343	114,9021	57346,75	89,3590	294,4159
8	18,5667	469	22,4510	378,6848	123,2018	64133,88	99,9349	394,3508
9	17,3360	399	23,5203	353,4036	116,1075	62714,68	97,7235	492,0743
10	18,2749	399	24,1488	372,4345	122,9762	67865,08	105,7490	597,8233
11	18,6980	399	24,4268	381,0582	126,0786	70230,02	109,4341	707,2573
12	19,1260	399	24,7047	389,6819	129,1810	72649,20	113,2037	820,4610




Figura 45: Comportamiento de CO2 capturado periodicamente

Fuente: Autor

#### 4.8 Discusión de los resultados:

**Estudio de la Densidad de la especie:** Los resultados obtenidos en el punto 4.1.1 indican que el valor del parámetro “b” difiere significativamente del propuesto por Reineke (1933) de -1,605 que se mantenía constante para un determinado número de especies. De

acuerdo a lo anteriormente señalado, el presente estudio ha revelado variaciones en dicho parámetro. Dado que la melina (*Gmelina arborea*) no es una planta nativa de la región del Tolima, pero que es una especie de alto interés comercial, se hace necesario realizar estudios de IDR junto con diagramas de manejo de densidad para esta especie, siendo éste uno de los primeros para la región. Queremos resaltar el hecho que, al trabajar sobre plantaciones forestales, es escaso encontrar rodales sin ningún tipo de intervención silvícola que permita encontrar los límites de máxima densidad y autoraleo. Sin embargo, en las plantaciones que incluimos en este trabajo, se encuentran rodales cuyo delta de crecimiento del diámetro medio cuadrático de la parcela es casi nulo y con edades por encima de los turnos de aprovechamiento.

Arias y Campos (1988), reporta para la especie en Costa Rica un IDR máximo de 986. Para su estimación fue calculado el valor de la constante de Reineke en la ecuación del IDR a partir de la información de 20 parcelas en autorraleo y cuyo valor es de -1,998. Estos datos difieren de los presentados en este trabajo, en donde la estimación realizada para "b" es de -1,8008 y un  $IDR_{Máx}$  de 572. La importancia del cálculo del  $IDR_{Máx}$  del rodal, radica en que este es un parámetro de restricción a tener en cuenta durante la simulación.

Las zonas de densidad establecidas toman como referencia lo propuesto por Ortiz (1986), Arias y Campos (1988) y Arias (2004), quienes reconocen 4 zonas de densidad (Gráfico 2). En la zona 1 (zona de subutilización del sitio) la densidad del rodal es baja y los árboles crecen en forma aislada. El crecimiento por árbol es máximo mientras que el crecimiento/Ha del rodal es mínimo, pero este se incrementa a medida que se aumenta el número de árboles/Ha. En la zona 2 (zona de transición) el crecimiento individual de los árboles comienza a disminuir y el crecimiento/Ha del rodal aumenta debido al incremento de la densidad. Si se desea maximizar el crecimiento/árbol para producir madera para aserrar se debe evitar que la densidad del rodal supere el límite superior de esta zona; y si por el contrario se quiere maximizar el crecimiento/Ha se debe evitar que después de un raleo, la densidad sea inferior al límite superior de esta zona. Zona 3 (zona de máximo crecimiento/Ha) el crecimiento/árbol tiende a ser mínimo a medida que aumenta la densidad, pero el crecimiento/Ha alcanza su máximo. Si el objetivo de la plantación es producir madera para postes, pulpa o leña se debe mantener la densidad del rodal dentro de la zona. Por último, la zona 4 (zona de autoraleo) es la zona donde el límite superior está dado por el  $IDR_{Máx}$  de la especie; hacia el límite superior de esta zona los árboles empiezan a morir por exceso de competencia (autoraleo), el crecimiento/Ha y el

crecimiento/árbol es mínimo, por lo tanto la plantación debe realizar un raleo si la densidad se ubica dentro de esta zona.

**Modelo de crecimiento con índice de competencia:** de los índices encontrados en la literatura, se descartaron aquellos que se calculan a partir de los radios de copa, debido a inconvenientes técnicos al momento de su medición. Con los índices de competencia tanto dependientes como independientes de la distancia al aplicarlos a las ecuaciones 3.1 3.2 y 3.3 se obtienen valores del estadístico R<sup>2</sup> por debajo de 0,5. Para su cálculo se escoge el árbol promedio de la parcela junto con sus vecinos (competidores). Con los resultados se concluye que no son aptos para modelar por si solos el crecimiento de los árboles y se corrobora lo concluido por Álvarez Taboada et all (2004). Su estudio sirvió para seleccionar el índice que será utilizado en las ecuaciones 3.5 y 3.6 y como parámetro de entrada a la RNA. Igualmente, de la revisión de los modelos lineal (3.1), exponencial (3.2) y potencial (3.3), se encontró que índice de competencia dependiente de la distancia de Hegyi, como se corrobora en (Álvarez-Taboada et al., 2003), se destaca en casi todos los 3 modelos, y por ser calculado a partir de los diámetros normales, se considera el índice adecuado para incluir en los modelos de Red Neuronal.

De los modelos 3.4, 3.5 y 3.6 concluimos que en efecto la competencia influye significativamente en los estadísticos. Lo que muestra que incluir los índices de competencia en los modelos logarítmicos (3.5) y (3.6) mejora el resultado de los estadísticos de correlación, indicando que al incluir el índice de competencia en el modelo permite simular el proceso de manera más eficiente. Es decir, los resultados indican que el crecimiento de *Gmelina arborea* Roxb, (y de los bosques plantados en general) se puede simular con mayor precisión utilizando modelos que incluyen los índices de competencia. Los resultados de este modelo empírico servirán para validar los resultados que se obtengan con la red Neuronal Artificial.

**Implementación de la Red Neuronal Artificial:** La implementación de la RNA se realizó con la ayuda de dos herramientas, en primer lugar, con programación en el lenguaje Python, mediante el uso de las librerías de Keras de TensorFlow y en segundo lugar utilizando el software MatLab . En la red neuronal implementada en Python se realizó la tarea de aumentar el número de capas ocultas de la red, así como el número de neuronas

artificiales sin obtener cambios significativos en el valor del Error Medio Cuadrático EMC y mediante la correlación entre lo simulado y el objetivo. La tabla 34, en los anexos, muestra como la red neuronal de una sola capa presenta el menor valor de Error Cuadrático Medio. Para la implementación de la RNA en Matlab, los autores proponen una sola capa oculta y mediante su algoritmo de retropropagación, el optimizador Levenberg-Marquardt, su modelo converge rápidamente al error mínimo permitido (ver Figura 20). Para nuestro caso lo realizó en tan solo 8 ciclos. Se corrobora la teoría de RNA de MatLab, que asegura que para la construcción de modelos de predicción es suficiente una sola capa oculta.

Los parámetros de competencia que se entregan a la red (número de árboles vecinos e Índice de competencia de Hegyi) se recalculan para cada árbol que se entrega a la red en cada nuevo ciclo (época), durante su entrenamiento.

Tanto para la implementación de la red Neuronal Artificial en Python, con el uso de la librería Keras, como con la RNA implementada en Matlab, los hiperparámetros tasa de aprendizaje (Learning rate) y momentum, en los algoritmos de retropropagación (Optimizador SGD y Levenberg-Marquardt), son manejados con valores por defecto. De acuerdo con la documentación de Keras, la tasa de aprendizaje por defecto es de 0,01 y esta se puede disminuir en cada época a partir de la activación de un valor de decremento (decay parameter), el cual hace que decaiga en una proporción de Tasa inicial/épocas. Por defecto el Momentum tiene un valor de 0 (<https://keras.io/api/optimizers/sgd/>)

La Red Neuronal Artificial en Matlab, entrega resultados iniciales y de parada del Numero de ciclos (épocas) que se necesitaron antes de converger al error mínimo tolerado, tiempo de entrenamiento, desempeño del modelo, y valores del gradiente y de Momentum (ver tabla 17). El error medio cuadrático del modelo mejoró comparado al obtenido mediante programación con la librería Keras de Python (ver tabla 18).

En las tablas 19 y 20 se muestra el comportamiento del modelado del crecimiento de la especie sin incluir la competencia (5 variables de entrada) e incluyendo las variables de competencia: número de vecinos e índice de competencia de Hegyi. Se observa el mejor desempeño con la inclusión de la competencia.

**Simulación del Crecimiento del rodal basado en Autómatas Celulares:** Recordemos que los Autómatas Celulares son reconocidos por su capacidad para modelar sistemas complejos a partir de estructuras simples. Los CA suelen describirse como sistemas dinámicos discretos que presentan una capacidad de computabilidad universal.

Su belleza radica en su simple interacción local y el cálculo de las células, lo que da como resultado un comportamiento enorme y complejo cuando estas células actúan juntas.

En los últimos años, la noción de sistemas complejos demostró ser un concepto muy útil para definir, describir y estudiar diversos fenómenos naturales observados en un gran número de disciplinas científicas. A pesar de su sencillez, son capaces de describir y reproducir muchos fenómenos complejos [13]. Están estrechamente relacionados con procesos como la autoorganización y la emergencia, a menudo observados en varias disciplinas científicas: biología, química y física, procesamiento y generación de imágenes, criptografía, nuevo hardware informático y diseños de algoritmos (es decir, redes de autómatas o algoritmos de deconvolución), entre muchos otros [14]. CA también se ha implementado satisfactoriamente para la heurística [15] y la programación de trabajos [16]. Además, la capacidad de realizar computación universal [17] ha sido una de las características más celebradas de CA. Han llamado la atención de la comunidad investigadora [18] debido al hecho de que una máquina de Turing arbitraria puede ser simulada por un autómata celular, por lo que la computación universal es posible [9].

Los valores iniciales de la simulación son aleatorios con distribución normal, de acuerdo a las mediciones de las parcelas con edades cercanas al año de edad, con media aritmética 4,2 y desviación estándar 1,5.

#### **Análisis de las políticas de Raleo con un Algoritmo Geneético:**

En aras a encontrar una mejor política de tiempos e intensidad de raleos, se implementó un Algoritmo Genético que consta de  $n-1$  cromosomas, donde  $n$  es el año de aprovechamiento total de la plantación. Para nuestro caso se simuló la fecha de corte a los 12 años. De esta forma un cromosoma de cada individuo de la población consta de 11 genes. El primer gen contiene la información de los periodos en los que se llevará a cabo el raleo. Para facilidad del algoritmo los diez genes restantes indican la intensidad del raleo que se llevaría a cabo en el periodo correspondiente a cada año, en caso de haber sido seleccionado el correspondiente año a ralear.

Para cada individuo de la población (política de raleo) se calcula, con ayuda del simulador diseñado (que actúa como función de desempeño del Algoritmo Genético), su respuesta a un conjunto de 10 poblaciones aleatorias generadas con una distribución normal con media 4,2 y desviación estándar 1,5 tomando como valor resultante el

---

promedio de volumen de las 10 poblaciones. Se clasifican los individuos de acuerdo al volumen final resultante y se guarda en un histórico de población al individuo con la mejor política obtenida de cada generación junto con el volumen obtenido. Al final de las 60 generaciones se obtendrá como respuesta la simulación de la política que mejor desempeño tuvo, junto con el mayor valor de volumen obtenido.

El resultado del Algoritmo Genético se debe entender no como el óptimo global, sino como una buena aproximación al óptimo global, o en el peor de los casos como un óptimo local. Por otro lado, como se definió anteriormente, la solución completa es **NP-Hard** ("Computational Complexity in Markov Decision Theory", Tsitsiklis, 2014), pero para efectos de simulación y disminuir su complejidad, se realizaron una serie de restricciones: Se toman para la simulación y comparación, las mismas 10 distribuciones aleatorias de plantaciones y por otro lado el porcentaje de árboles a cortar (intensidad de raleo), se toma en múltiplos de 5 hasta 80. Igualmente hay una restricción en el número de generaciones (60)

Con la mejor política de tiempo e intensidad de raleo encontrada por el algoritmo genético, se calcula la biomasa y su correspondiente captura de carbono, para efectos de comercializarlos periódicamente en bonos de carbono.

Los resultados obtenidos muestran que se cumplieron los propósitos de la investigación y esta metodología es aplicable a diferentes especies maderables. Se considera que, con algunos ajustes, sería aplicable a diferentes zonas climáticas.

## 5 Conclusiones y recomendaciones

### 5.1 Conclusiones

- Se concluye que la red neuronal artificial es una herramienta adecuada para modelar el crecimiento y rendimiento de un árbol en una plantación forestal, y por sus características permite involucrar la influencia de la competencia en el sistema.
- La combinación del modelo de Red Neuronal Artificial con el Autómata celular, donde las reglas de transición se basan en indicadores de competencia, logra simular el comportamiento no lineal del crecimiento del rodal ante las intervenciones de raleo.
- Aunque el costo en tiempo computacional es elevado, se logra que la simulación implementada con autómatas celulares, sea considerada una buena opción como función de desempeño (fitness function) del Algoritmo Genético .
- Se considera que el diseño final del cromosoma es el adecuado para que el Algoritmo Genético represente los tiempos e intensidad del raleo de tal forma que facilita la implementación de los operadores genéticos.
- Este trabajo logra conseguir sus objetivos planteados, al proponer una metodología que, basada en un conjunto de herramientas de la inteligencia computacional, se modele el crecimiento de la especie forestal *Gmelina arborea* Roxb. en el Departamento del Tolima y se simulan las estrategias silviculturales de manejo de densidad (raleo), con miras a alcanzar un óptimo rendimiento en la producción de madera al final de la cosecha.
- La metodología planteada se puede implementar para otras especies forestales que cuenten con mediciones de parcelas permanentes.

Se pueden considerar los siguientes aportes:

- La Red Neuronal Artificial como modelo de crecimiento junto con el autómata celular, permiten no solo elevar un modelo de crecimiento de árbol individual a modelo de crecimiento de plantación, sino que también es capaz de simular la

dinámica de los proceso de intervención de densidad (raleo), aplicados a las plantaciones forestales.

- Una vez establecido un rodal forestal (plantación), con las mediciones alométricas del primer año, este simulador podrá estimar con menor incertidumbre el crecimiento de toda la plantación e igualmente determinar una política de raleo ajustada a la plantación.
- Aproximar el sistema a la máxima producción de madera de la especie forestal promisorio *Gmelina arborea* Roxb., al encontrar una política de intensidad y tiempos de raleo, mejorada a través de la implementación de un Algoritmo Genético.
- El cálculo del volumen de madera obtenido a través del modelo, se utilizó para así mismo calcular la captura de carbono acumulado que obtiene el rodal (plantación).

## 5.2 Investigaciones futuras

- Herramienta para estimar los valores de Índice de Sitio sin tener que esperar a que el rodal tenga la edad de cosecha, a partir de condiciones de suelo humedad temperatura y precipitación, estudio que se está desarrollando por el grupo Maderas y Bosques.
- Se espera mejorar los indicadores de eficiencia del modelo respecto al sitio, agregando la variable climática de precipitación, con su predicción a partir de los registros históricos mensuales de las estaciones meteorológicas próximas a los rodales estudiados, que ya se encuentran disponibles.
- La Universidad del Tolima tiene un ensayo de *Gmelina arborea* en la granja de Armero y de la especie *Tectona grandis* en donde se pretende establecer parcelas permanentes, con las cuales también se podrá aplicar toda la metodología utilizada en este trabajo.
- Analizar los valores obtenidos de tiempo de raleo e intensidad con el diagrama de Hart-Beiking de forma automatizada, como otra forma de mostrar los resultados (ver figura 20)

12 Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
2 la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
Inteligencia Computacional

---

- Con las restricciones dadas al algoritmo genético, se puede realizar un estudio de métodos de optimización que encuentren la política óptima, para ello se sugiere el uso de simheurísticas y/o algoritmos meméticos

## REFERENCIAS

- Adeleke, A. A., Odusote, J. K., Lasode, O. A., Ikubanni, P. P., Malathi, M., & Paswan, D. (2019). Mild pyrolytic treatment of *Gmelina arborea* for optimum energetic yields. *Cogent Engineering*, 6(1). <https://doi.org/10.1080/23311916.2019.1593073>
- Allen, S. T., & Keim, R. F. (2017). Wetland-tree growth responses to hydrologic variability derived from development and optimization of a non-linear radial growth model. *Ecological Modelling*, 354, 49–61. <https://doi.org/10.1016/j.ecolmodel.2017.03.016>
- Álvarez-Taboada, M. F., Barrio-Anta, M., Gorgoso-Varela, J., & Álvarez-González, J. G. (2003). Influencia de la competencia en el crecimiento en sección en *Pinus radiata* D. Don. *Invest Agrar: Sist Recur For*, 12, 25–35.
- Álvarez Taboada, M. F., Marqués González, R., Fernández Manso, A., & Castedo Dorado, F. (2004). Influencia de la competencia en el crecimiento en sección de *Pinus Radiata* D. Don en el Bierzo (León). *Cuaderno de La Sociedad Española de Ciencias Forestales*, 18, 129–134.
- Amaya Arias, Á. M. (2020). Régimen jurídico-ambiental de los recursos forestales en Colombia. In *Syria Studies* (Primera ed, Vol. 7, Issue 1). Universidad Externado de Colombia. [https://www.forestalmaderero.com/wp-content/uploads/2022/02/MAGKB-spa-2020-Regimen\\_juridico-ambiental\\_de\\_los\\_recursos\\_forestales\\_en\\_Colombia-desbloqueado-1.pdf](https://www.forestalmaderero.com/wp-content/uploads/2022/02/MAGKB-spa-2020-Regimen_juridico-ambiental_de_los_recursos_forestales_en_Colombia-desbloqueado-1.pdf)
- Arias Aguilar, D. (2004). Validación del Índice de Densidad del Rodal para el manejo de plantaciones forestales de *Tectona grandis* L.f. en el trópico. In *Revista Forestal Mesoamericana Kurú* (Vol. 1, Issue 1, pp. 1–6). <http://medcontent.metapress.com/index/A65RM03P4874243N.pdf>
- Arias Aguilar, D., & Campos, N. (1987). *Evaluación de tres métodos para prescribir raleos*

*en plantaciones forestales de Pinus caribaea y Gmelina arborea en Pueblo Nuevo, Sarapiquí.* Instituto Tecnológico de Costa Rica.

- Ashraf, M. I., Meng, F. R., Bourque, C. P. A., MacLean, D. A., & Bond-Lamberty, B. (2015). A novel modelling approach for predicting forest growth and yield under climate change. *PLoS ONE*, *10*(7), 1–18. <https://doi.org/10.1371/journal.pone.0132066>
- Assmann, V. E. (1950). Grundflächen und Volumzuwachs der Rofbuche bei verschiedenen Durchforstungsgraden. *Forstwissenschaftliches Centralblatt*, *69*(5), 256–286.
- Barrios-Trilleras, A., López-Aguirre, A. M., & Báez-Aparicio, C. A. (2021). Modeling the productivity of *Gmelina arborea* Roxb. using biophysical and stand variables. *Colombia Forestal*, *24*(1), 71–87. <https://doi.org/10.14483/2256201X.15345>
- 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*(July), 104929. <https://doi.org/10.1016/j.compag.2019.104929>
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2014). *Neural Network Toolbox™ User's Guide R 2014 b*.
- Bertalanffy, L. v. (1941). Untersuchungen über die Gesetzlichkeit des Wachstums. VII. Stoffwechselformen und Wachstumstypen. *Biologisches Zentralblatt*, *61*, 510–532.
- Botkin, D. B. (1993). *Forest Dynamics an Ecological Model*. Oxford University Press.
- Botkin, D. B., Janak, J. F., & Wallis, J. R. (1972). Some Ecological Consequences of a Computer Model of Forest Growth. *The Journal of Ecology*, *60*(3), 849. <https://doi.org/10.2307/2258570>
- Breen, M., Murphy, M. D., & Upton, J. (2019). Development of a dairy multi-objective optimization (DAIRYMOO) method for economic and environmental optimization of dairy farms. *Applied Energy*, *242*(February), 1697–1711. <https://doi.org/10.1016/j.apenergy.2019.03.059>
- Buckman, R. E. (1962). Growth and yield of red pine in Minnesota. *Tech. Bull. 1272. USDA Forest Service*, 50.
- Cárcamo, C. N., Herrera, M. A., Aranda, F. D., & Donoso, P. J. (2011). Diagrama de manejo de densidad y su aplicación a raleo en bosques de segundo crecimiento de *Drimys winteri* en el sur de Chile. *Bosque*, *32*(2), 175–186. <https://doi.org/10.4067/S0717-92002011000200008>
- Castagneri, D., Vacchiano, G., Lingua, E., & Motta, R. (2008). Analysis of intraspecific

- competition in two subalpine Norway spruce (*Picea abies* (L.) Karst.) stands in Paneveggio (Trento, Italy). *Forest Ecology and Management*, 255(3–4), 651–659. <https://doi.org/10.1016/j.foreco.2007.09.041>
- Castro Pérez, S. N., & Borz, S. A. (2021). Improving the event-based classification accuracy in pit-drilling operations: An application by neural networks and median filtering of the acceleration input signal data. In *Sensors* (Vol. 21, Issue 18). <https://doi.org/10.3390/s21186288>
- Chen, F., Ma, Q., & Huang, W. (2019). Farm households' rice production behavior in China under a separability assumption: A metaheuristic optimization approach. *Natural Resource Modeling*, 32(3). <https://doi.org/10.1111/nrm.12221>
- Chen, S. H., Jakeman, A. J., & Norton, J. P. (2008). Artificial Intelligence techniques: An introduction to their use for modelling environmental systems. *Mathematics and Computers in Simulation*, 78(2–3), 379–400. <https://doi.org/10.1016/j.matcom.2008.01.028>
- Chigbundu Chijioke, E., Onipede, O. ., & Okonkwo Ikemsinachi, D. (2022). Sorption studies of phthalic acid esters uptake from lagos lagoon sample using characterized gmelina arborea pericarp biosorbent. *Separation Science and Technology (Philadelphia)*. <https://doi.org/10.1080/01496395.2022.2036761>
- Chikumbo, O., & Nicholas, I. (2011). Efficient thinning regimes for *Eucalyptus fastigata*: Multi-objective stand-level optimisation using the island model genetic algorithm. *Ecological Modelling*, 222(10), 1683–1695. <https://doi.org/10.1016/j.ecolmodel.2011.03.004>
- Clutter, J. L. (1963). Compatible Growth and Yield Models for Loblolly Pine. *Forest Science*, 9(3), 354–371.
- Corvalán, P., & Hernández, J. (2006). Densidad de rodal. In *Cátedra en Dasometría* (Issue Barasorda 1977).
- Crecente Campo, F., Vazquez Gómez, E., Rodríguez-Soalleiro, R., & Diéguez-Aranda, U. (2007). Influencia De La Competencia En El Crecimiento Individual De *Pinus Radiata* D. Don En Galicia. *Sociedad Española de Ciencias Forestales*, 174, 167–174.
- Curtis, R. O., Marshall, D. D., & Bell, J. F. (1997). LOGS A Pioneering Example of Silvicultural Research in Coast Douglas-Fie. *Forestry*, 95(7), 19–25.
- DANE, D. A. N. E. (2021). Cuenta ambiental y económica de Bosque. In *Dane*. [https://www.dane.gov.co/files/investigaciones/pib/ambientales/cuentas\\_ambientales/cuentas-residuos/Pt-Cuenta-Residuos-2016p.pdf](https://www.dane.gov.co/files/investigaciones/pib/ambientales/cuentas_ambientales/cuentas-residuos/Pt-Cuenta-Residuos-2016p.pdf)

- Dash, J. P., Moore, J. R., Lee, J. R., Klápště, J., & Dungey, H. S. (2019). Stand density and genetic improvement have site-specific effects on the economic returns from *Pinus radiata* plantations. *Forest Ecology and Management*, 446(January), 80–92. <https://doi.org/10.1016/j.foreco.2019.05.003>
- Departamento Nacional de Planeación. (2019). *Plan Nacional de Desarrollo 2018-2022: Pacto por Colombia, pacto por la equidad* (Vol. 38, Issue 68). <https://doi.org/10.19053/01203053.v38.n68.2019.9924>
- Departamento Nacional de Planeación. (2020). *Documento CONPES de Política nacional para el Control de la deforestación y la Gestión sostenible de los bosques*.
- Díaz Gómez, C. G., & Pava Gantivar, B. L. (2015). *Selección de estrategias silviculturales para la planificación de raleos en rodales de Gmelina arborea Roxb en el Departamento del Tolima*.
- Diéguez-Aranda, U., Alboreca, A. R., Castedo-Dorado, F., González, J. G. Á., Barrio-Anta, M., Crecente-Campo, F., González, J. M., González, Pérez-Cruzado, C., Soalleiro, R. R., López-Sánchez, C. A., Balboa-Murias, M. Á., Gorgoso, J. J., & Rodríguez, V. F. S. (2009). Herramientas silvícolas para la gestión forestal sostenible en Galicia. In *Universidad de Santiago de Compostela*.
- Escobedo Soto, A. S. (2014). *Diagrama de manejo de densidad para rodales naturales del Ejido El Largo, Chihuahua*. [Universidad Autónoma de Nuevo León]. <http://eprints.uanl.mx/4294/1/1080253739.pdf>
- FAO. (2020a). Global Forest Resources Assessment 2020 - Key findings. In *Global Forest Resources Assessment 2020*. FAO. <https://doi.org/10.4060/ca8753en>
- FAO. (2020b). Global Forest Resources Assessment 2020 - Main report. In *Global Forest Resources Assessment 2020*. <https://doi.org/10.4324/9781315184487-1>
- FAO. (2022). The State of the World's Forests 2022. Forest pathways for green recovery and building inclusive, resilient and sustainable economies. In *Fao*. <https://doi.org/10.4060/cb9360en>
- Fernández Tschieder, E., Goya, J. F., & Achinelli, F. (2013). Unidad IV: Modelos de crecimiento y rendimiento. In *Curso Silvicultura* (pp. 1–7).
- Fontes, L., Bontemps, J. D., Bugmann, H., Van Oijen, M., Gracia, C., Kramer, K., Lindner, M., Rotzer, T., & Skovsgaard, J. P. (2010). Models for supporting forest management in a changing environment. *Forest Systems*, 19, 8–29. <https://doi.org/10.5424/fs/201019S-9315>

- Fortin, M., Sattler, D., & Schneider, R. (2022). An alternative simulation framework to evaluate the sustainability of annual harvest on large forest estates. *Canadian Journal of Forest Research*, 52(5), 704–715. <https://doi.org/10.1139/cjfr-2021-0255>
- Fransson, P., Franklin, O., Lindroos, O., Nilsson, U., Brännström, Å., & For Res, C. J. (2020). A simulation-based approach to a near optimal thinning strategy-allowing for individual harvesting times for individual trees. *Canadian Journal of Forest Research*, 50(3), 320–331. <https://doi.org/10.1139/cjfr-2019-0053>
- Fuchs, M. (2018). *Roger Federer vs . Deep Learning Une intelligence artificielle peut-elle prédire la trajectoire du service de Federer?* (Issue September). Université de Neuchatel.
- Gadow, K. V., Sánchez Orois, S., & Álvarez González, J. G. (2007). *Estructura y Crecimiento del Bosque* (UNICOPIA & Lugo (eds.)). UNICOPIA . Lugo.
- Gezan, S. A., Ortega, A., & Andenmatten, E. (2007). Diagramas de manejo de densidad para renovales de roble , raulí y coigüe en Chile. *Bosque (Valdivia)*, 28(2), 97–105. <https://doi.org/10.4067/S0717?92002007000200002>
- González, M. Y. (2004). *Estudio de inventario forestal regional y opciones de mercado para el nucleo Bajo Magdalena*.
- Görgens, E. B., Montaghi, A., & Rodriguez, L. C. E. (2015). A performance comparison of machine learning methods to estimate the fast-growing forest plantation yield based on laser scanning metrics. *Computers and Electronics in Agriculture*, 116, 221–227. <https://doi.org/10.1016/j.compag.2015.07.004>
- H. Deutschman, D., Levin, S. A., Devine, C., & Buttel, L. A. (1997). Scaling from Trees to Forests: Analysis of a Complex Simulation Model. *Science*, 277(5332), 1684. <https://doi.org/10.1126/science.277.5332.1684b>
- Hartig, G. . (1795). *Anweisung zur Taxation und Beschreibung der Forste, oder zur Bestimmung des Holzertrages der Wälder. Gießen*.
- Hassani, L., Daneshvar kakhki, M., Sabouhi sabouni, M., & Ghanbari, R. (2019). The optimization of resilience and sustainability using mathematical programming models and metaheuristic algorithms. *Journal of Cleaner Production*, 228, 1062–1072. <https://doi.org/10.1016/j.jclepro.2019.04.324>
- Holdridge, L. R. (1947). Determination of World Plant Formations From Simple Climatic Data. *Science*, 105(2727), 367–368. <https://doi.org/https://doi.org/10.1126/science.105.2727.367>
- Holland, J. H. (1992). Computer programs that “evolve” in ways that resemble natural

- selection can solve complex problems even their creators do not fully understand. *Genetic Algorithms*, 267(1), 66–73.
- Iwuoha, S. E., Seim, W., & Onyekwelu, J. C. (2021). Mechanical properties of *Gmelina arborea* for engineering design. *Construction and Building Materials*, 288. <https://doi.org/10.1016/j.conbuildmat.2021.123123>
- Jansson, G., Kerr, R., Dutkowski, G., & Kroon, J. (2017). Competition effects in breeding value prediction of forest trees. *Canadian Journal of Forest Research*.
- Jia, W., Sun, Y., Pukkala, T., & Jin, X. (2020). Improved Cellular Automaton for Stand Delineation. *Forest*, 11(1), 539–547.
- Kahriman, A., Şahin, A., Sonmez, T., & Yavuz, M. (2019). A novel approach to selecting a competition index: the effect of competition on individual tree diameter growth of *Calabrian pine*. 48(10), 1–35. <https://doi.org/10.1139/cjfr-2018-0092>
- Koster, R., & Fuchs, J. M. (2022). Opportunity costs of growing space – an essential driver of economical single-tree harvest decisions. *Forest Policy and Economics*, 135(December 2021), 102668. <https://doi.org/10.1016/j.forpol.2021.102668>
- Kuehne, C., McLean, J. P., Maleki, K., Antón-Fernández, C., & Astrup, R. (2022). A stand-level growth and yield model for thinned and unthinned even-aged Scots pine forests in Norway. *Silva Fennica*, 56(1), 1–21. <https://doi.org/10.14214/sf.10627>
- Langsaeter, A. (1941). Om tynning i enaldret gran- og furuskog. *Maddel. Det Norske Skogforoksesvesen*, 8.
- Lee, D., & Choi, J. (2019). Evaluating maximum stand density and size–density relationships based on the Competition Density Rule in Korean pines and Japanese larch. *Forest Ecology and Management*, 446(February), 204–213. <https://doi.org/10.1016/j.foreco.2019.05.017>
- Leslie, P. H. (1945). On the use of matrices in certain population mathematics. *Biometrika*, 33, 183–212.
- Lett, C., Silber, C., & Barret, N. (1999). Comparison of a cellular automata network and an individual-based model for the simulation of forest dynamics. *Ecological Modelling*, 121(2–3), 277–293. [https://doi.org/10.1016/S0304-3800\(99\)00090-3](https://doi.org/10.1016/S0304-3800(99)00090-3)
- Long, J. N. (1985). A Practical Approach to Density Management. *The Forestry Chronicle*, 61(1), 23–27. <https://doi.org/10.5558/tfc61023-1>
- López, A. M., Trincado, G., Barrios, A., & Nieto, V. (2013). Modelos regionales de altura-diámetro para plantaciones jóvenes de *Eucalyptus tereticornis* en la costa atlántica

- colombiana. *Bosque*, 34(2), 233–241. <https://doi.org/10.4067/S0717-92002013000200012>
- MacKinney, A. L., & Chaiken, L. E. (1939). Volume, yield and growth of loblolly pine in the mid-atlantic region. *U.S. Forest Service*.
- Mäkinen, H., & Isomäki, A. (2004). Thinning intensity and growth of Norway spruce stands in Finland. *Forestry*, 77(4), 349–364. <https://doi.org/10.1093/forestry/77.4.349>
- Martínez H, Héctor A. 2015, Melina (*Gmelina arborea* Roxb.): condiciones para su cultivo “Fomento de la reforestación comercial para la mejora y conservación de las reservas de carbono”, Fondo Nacional de Financiamiento Forestal Forest Monitoring
- Martins Silva, J. P., Marques da Silva, M. L., Ferreira da Silva, E., Fernandes da Silva, G., Ribeiro de Mendonça, A., Cabacinha, C. D., Araújo, E. F., Santos, J. S., Vieira, G. C., Felix de Almeida, M. N., & Fernandes, M. R. de M. (2019). Computational techniques applied to volume and biomass estimation of trees in Brazilian savanna. *Journal of Environmental Management*, 249. <https://doi.org/10.1016/j.jenvman.2019.109368>
- Melo Cruz, O. (2014). *Modelación del Crecimiento, Acumulación de biomasa y Captura de Carbono en Arboles de Gmelina arborea Roxb., Asociados a sistemas Agroforestales y Plantaciones Homogéneas en Colombia*. 148.
- Messerer, K., Kacprowski, T., Kolo, H., Baumbach, J., & Knoke, T. (2020). Importance of considering the growth response after partial harvesting and economic risk of discounted net revenues when optimizing uneven-aged forest management. *Canadian Journal of Forest Research*, 50(5), 487–499. <https://doi.org/10.1139/cjfr-2018-0546>
- Ministerio de Agricultura y Desarrollo Rural. (2021). *Boletín Estadístico Forestal*.
- Ministerio de Ambiente y Desarrollo Sostenible. (2000). Plan nacional de desarrollo forestal. In *Diario Oficial*.
- Ministerio de Ambiente y Desarrollo Sostenible. (2020). *Lineamientos y guía para la Ordenación Forestal en Colombia*.
- Munro, D. D. (1974). Forest growth models - a prognosis Growth models for tree and stand simulation. In *Proc. IUFRO Meeting S4.01.04, Research Notes*, N. 30.
- Newnham, R. M. (1964). *The development of a stand model for Douglas fir*. The University of British Columbia.
- Newnham, R. M., & Smith, J. H. G. (1964). *Development and Testing of Stand Models for Douglas F I R and Lodgepole Pine*1. 66.
- Nunes, M. H., & Görgens, E. B. (2016). Artificial Intelligence Procedures for Tree Taper

- Estimation within a Complex Vegetation Mosaic in Brazil. *PLoS ONE*, 11(5), 1–16.  
<https://doi.org/10.1371/journal.pone.0154738>
- Nyland, R. (2016). *Silviculture: concepts and applications* (Tercera ed). Waveland Press.
- Obando Bonilla, D. (2004). INTERCEPTACIÓN DE LA RADIACION, ACUMULACION Y DISTRIBUCION DE BIOMASA Y CONTENIDO DE CARBONO EN *Gmelina arborea* Roxb y *Pochota quinata* (Jacq) Dugand. In *Atmospheric Environment* (Vol. 38, Issue 5). <http://dx.doi.org/10.1016/j.buildenv.2015.02.015>
- Obregón Sánchez, C. (2006). *Gmelina* arbórea. Versatilidad, renovación y productividad sostenible para el futuro. *Revista Mueble y La Madera (M&M)*, 14–20.
- Ohland, C. 2000. Recomendaciones para el manejo de *Gmelina arborea*. MINAE-ITCR-COSEFORMA-CCF-GTZ. Costa Rica. 53 p
- ONF Andina. (2018). *Estudios de Economía forestal en el marco de la Misión de Crecimiento Verde en Colombia*.
- Ortiz, E. (1986). *Utilización del IDR en el manejo de la densidad de plantaciones forestales*.
- Pacala, S. W., Canham, C. D., & Silander Jr., J. A. (1993). Forest models defined by field measurements: I. The design of a northeastern forest simulator. *Canadian Journal of Forest Research*, 23(10), 1980–1988. <https://doi.org/10.1139/x93-249>
- Patiño, S., Suárez, L. N., Andrade, H. J., & Segura, M. A. (2018). Captura de carbono en biomasa en plantaciones forestales y sistemas agroforestales en Armero-Guayabal, Tolima, Colombia. *Revista de Investigación Agraria y Ambiental*, 9(2), 122–133.
- Ponce Cruz, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería* (Primera ed). Alfaomega Grupo Editor, S.A. de C.V., México. <http://www.alfaomega.com.mx>
- Pretzsch, H. (2009). *Forest Dynamics, Growth and Yield*.
- Pretzsch, H. (2010). Forest Dynamics, Growth, and Yield. In *Springer*.  
<https://doi.org/10.1007/978-3-540-88307-4>
- Pretzsch, H. (2020). Density and growth of forest stands revisited. Effect of the temporal scale of observation, site quality, and thinning. *Forest Ecology and Management*, 460(September 2019), 117879. <https://doi.org/10.1016/j.foreco.2020.117879>
- Ramos Molina, P. A., & Niño López, G. S. (2017). *Modelamiento de atributos fustales y volúmenes comerciales de árboles de Gmelina arborea creciendo en del Departamento del Tolima*.
- Reineke, L. H. (1927). A modification of bruce's method of preparing timber-yield tables. *Journal of Agricultural Research*, 35(9), 843–856.

- Reineke, L. H. (1933). Perfecting a stand-density index for even-aged forests. *J. Agric. Res.*, 46(7), 627–638.
- Reis, L. P., de Souza, A. L., dos Reis, P. C. M., Mazzei, L., Soares, C. P. B., Miquelino Eleto Torres, C. M., da Silva, L. F., Ruschel, A. R., Rêgo, L. J. S., & Leite, H. G. (2018). Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. *Ecological Engineering*, 112(April 2017), 140–147. <https://doi.org/10.1016/j.ecoleng.2017.12.014>
- Reyes-Muñoz, J. L., Aguirre Calderón, Ó. A., Jiménez-Pérez, J., Treviño-Garza, E. J., Jurado, E., & González-Laredo, R. F. (2011). Modelos De Predicción Del Incremento En Volumen Para Bosques Mezclados Del Estado De Durango, México. *Revista Chapingo Serie Ciencias Forestales y Del Ambiente*, XVII(1), 103–113. <https://doi.org/10.5154/r.rchscfa.2010.05.026>
- Reyes Gómez, D. A. (2011). Descripción y Aplicaciones de los Autómatas Celulares. *Verano de Investigación 2011*, 1–26.
- Richards, M., McDonald, A. J. S., & Aitkenhead, M. J. (2008). Optimisation of competition indices using simulated annealing and artificial neural networks. *Ecological Modelling*, 214(2–4), 375–384. <https://doi.org/10.1016/j.ecolmodel.2008.03.008>
- Rodriguez Santos, Nathaly. (2013). *GUÍA PARA LA CUANTIFICACIÓN DE LA BIOMASA Y EL CARBONO FORESTAL, GENERACIÓN DE MODELOS Y USO DE HERRAMIENTAS PARA SU ESTIMACIÓN*. Corporación Autónoma Regional De Cundinamarca - CAR Subdirección de Administración de los Recursos Naturales y Áreas Protegidas Bogotá D.C. Colombia. Abril de 2013.
- Rojas Rodríguez, F., Arias Aguilar, D., Moya Roque, R., Meza Montoya, A., Murillo Gamboa, O., & Marcela Gamboa, A. (2004). Manual para productores de melina Gmelina arborea en Costa Rica. In *Sistema de Información de los Recursos Forestales de Costa Rica (SIREFOR)*. [http://www.sirefor.go.cr/Documentos/Especies\\_plantaciones/MELINA/Manual para los productores de melina.pdf](http://www.sirefor.go.cr/Documentos/Especies_plantaciones/MELINA/Manual_para_los_productores_de_melina.pdf) <http://www.sirefor.go.cr>
- Salas, C., Gregoire, T. G., Craven, D. J., & Gilabert, H. (2016). Modelación del crecimiento de bosques: Estado del arte. *Bosque*, 37(1), 3–12. <https://doi.org/10.4067/S0717-92002016000100001>
- Schneider. (1853). *Jahrbuch zum Forst- und Jagdkalender für Preußen*.
- Schumacher, F. X. (1939). A new growth curve and its application to timber yield studies. *Journal of Forestry*, 37(819-820 (1939)), 33.

- Shifley, S. R., He, H. S., Lischke, H., Wang, W. J., Jin, W., Gustafson, E. J., Thompson, J. R., Thompson, F. R., Dijak, W. D., & Yang, J. (2017). The past and future of modeling forest dynamics: from growth and yield curves to forest landscape models. *Landscape Ecology*, *32*(7), 1307–1325. <https://doi.org/10.1007/s10980-017-0540-9>
- Skudnik, M., & Jevšenak, J. (2022). Artificial neural networks as an alternative method to nonlinear mixed-effects models for tree height predictions. *Forest Ecology and Management*, *507*(October 2021). <https://doi.org/10.1016/j.foreco.2022.120017>
- Sola, G., Attis Beltrán, H., Chauchard, L., & Gallo, L. (2015). Efecto del manejo silvicultural sobre la regeneración de un bosque de *Nothofagus dombeyi*, *N. Alpina* y *N. obliqua* en la Reserva Nacional Lanín (Argentina). *Bosque*, *36*(1), 113–120. <https://doi.org/10.4067/S0717-92002015000100012>
- Stage, A. R. (1973). Prognosis model for stand development. In *USDA Forest Service Research Paper INT-137*.
- Sterba, H., & Monserud, R. A. (1997). Applicability of the forest stand growth simulator prognos for the Austrian part of the Bohemian Massif. *Ecological Modelling May 1997*, *98*(1), 23–34.
- Sun, H., Diao, S., Liu, R., Forrester, D., Soares, A., Saito, D., Dong, R., & Jiang, J. (2018). Relationship between size inequality and stand productivity is modified by self-thinning, age, site and planting density in *Sassafras tzumu* plantations in central China. *Forest Ecology and Management*, *422*(November 2017), 199–206. <https://doi.org/10.1016/j.foreco.2018.02.003>
- Sun, S., Cao, Q. V., & Cao, T. (2019). Evaluation of distance-independent competition indices in predicting tree survival and diameter growth. *Canadian Journal of Forest Research*, *49*(5), 1–32.
- Tamarit-Urias, J. C., Quiñonez-Barraza, G., De los Santos-Posadas, H. M., Castañeda-Mendoza, A., & Santiago-García, W. (2019). Diagrama para manejo de la densidad en rodales de *Pinus patula* Schiede ex Schltdl. & Cham. en Puebla, México. *Revista Mexicana de Ciencias Forestales*, *10*(51), 25.
- Thiffault, N., Hoepfing, M. K., Fera, J., Lussier, J.-M., & Larocque, G. R. (2021). Managing plantation density through initial spacing and commercial thinning: yield results from a 60-year-old red pine spacing trial experiment. *Canadian Journal of Forest Research*, *51*(2), 879. <https://doi.org/10.1139/cjfr-2021-0126>
- Thurm, E. A., & Pretzsch, H. (2021). Growth–density relationship in mixed stands – Results

- from long-term experimental plots. *Forest Ecology and Management*, 483, 118909. <https://doi.org/10.1016/j.foreco.2020.118909>
- Tudoroiu, N., Chiru, C., & Grigore, M. (2009). Neural Networks Architectures for Modeling and Simulation of the Economy System Dynamics. *Journal of Academic Research in Economics*, 1(1), 93–116. [http://www.jare-sh.com/downloads/num\\_1\\_issue\\_1\\_2009/tudoroiu.pdf](http://www.jare-sh.com/downloads/num_1_issue_1_2009/tudoroiu.pdf)
- Universidad del Tolima. (2009). *Sistematización y modelación de información económica y técnica para la capacitación de profesionales vinculados a la producción, transformación y comercialización de productos maderables - Segunda fase*.
- Usher, M. B. (1966). A matrix approach to the management of renewable resources, with special reference to selection forests. *Journal Appl. Ecol.*, 3, 355–367.
- Vallejos, J.; Moya, R.; Serrano, R. 2015. Effects of thinning on diameter, heartwood, density and drying defects of *Gmelina arborea*. *Maderas-Cienc Tecnol* 17(3):2015
- Vanclay, J. K. (1989). A growth model for north Queensland rainforests. *For. Ecol. Manage*, 27, 245–271.
- Vanclay, J. K. (1994). *Modelling Forest Growth and Yield: Applications to Mixed Tropical Forests*. CAB International.
- Vanclay, J. K. (2003). Growth modelling and yield prediction for sustainable forest management. *The Malaysian Forester*, 66(2003), 58–69.
- Vieira, G. C., de Mendonça, A. R., da Silva, G. F., Zanetti, S. S., da Silva, M. M., & dos Santos, A. R. (2018). Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. *Science of the Total Environment*, 619–620, 1473–1481. <https://doi.org/10.1016/j.scitotenv.2017.11.138>
- Weiskittel, A. R., Hann, D. W., Kershaw, J. A., & Vanclay, J. K. (2011). Forest Growth and Yield Modeling. In *Forest Growth and Yield Modeling*. <https://doi.org/10.1002/9781119998518>
- West, J. (2019). Multi-criteria evolutionary algorithm optimization for horticulture crop management. *Agricultural Systems*, 173(November 2017), 469–481. <https://doi.org/10.1016/j.agsy.2019.03.016>
- Xue, H., Mäkelä, A., Valsta, L., Vanclay, J. K., & Cao, T. (2019). Comparison of population-based algorithms for optimizing thinnings and rotation using a process-based growth model. *Scandinavian Journal of Forest Research*, 34(6), 458–468. <https://doi.org/10.1080/02827581.2019.1581252>
- Yi, L., Li, H., Guo, J., Deussen, O., & Zhang, X. (2018). Tree growth modelling constrained

by growth equations. *Computer Graphics Forum*, 37(1), 239–253.  
<https://doi.org/10.1111/cgf.13263>

Yoosefzadeh-Najafabadi, M., Tulpan, D., & Eskandari, M. (2021). Application of machine learning and genetic optimization algorithms for modeling and optimizing soybean yield using its component traits. *PLoS ONE*, 16(4 April), 1–18.  
<https://doi.org/10.1371/journal.pone.0250665>

Zeide, B. (2001). Thinning Growth: and A Full Turna. *Forestry*, 99(1), 20–25.

Zeide, B. (2005). How to measure stand density. *Trees - Structure and Function*, 19(1), 1–14. <https://doi.org/10.1007/s00468-004-0343-x>

Zhai, Z., Martínez Ortega, J. F., Martínez, N. L., & Rodríguez-Molina, J. (2018). A mission planning approach for precision farming systems based on multi-objective optimization. *Sensors (Switzerland)*, 18(6). <https://doi.org/10.3390/s18061795>

## **ANEXOS**

## ANEXO 1 : VALORES DE LOS INDICES

Cálculo de índices independientes de la distancia.

No Parcela	Índice FCC	BAL	Balrel	Balmod	Reinike	Hart IH	N.PIES.H
1	3696,08611	8622,76077	6141,81254	1812,5975	273,852503	0,30750775	3437,5
2	5948,39609	7294,38544	4862,92363	625,921558	389,876293	0,38846111	4375
3	4618,50023	9811,70586	5771,59168	1176,99723	535,528156	0,24518289	6250
4	5005,875	9611,67398	5715,78003	1168,31	439,208591	0,2446184	5000
5	7584,09919	9862,67089	7586,66992	1329,42726	458,590504	0,28533603	5312,5
6	5591,76445	11760,505	6917,9441	1755,42874	669,005415	0,19704429	7968,75
7	3522,21742	10843,5291	6777,20566	1462,24396	582,943265	0,23173991	6875
8	5929,69114	6798,68925	6180,62659	1076,76689	663,04726	0,28699929	7968,75
9	4689,64346	7003,54858	4669,03238	989,27861	630,557522	0,23598167	7500
10	3831,81621	8857,62137	5905,08091	2019,53767	654,476303	0,23391813	7812,5
11	3406,29534	8252,78279	4584,87933	1591,95303	596,551087	0,23040274	7031,25
12	4274,09079	13542,9975	6771,49876	2798,19108	720,396588	0,19359646	8593,75
14	4570,91914	7114,04624	5472,34326	1808,47425	700,503129	0,24207558	8437,5
15	3673,03582	8146,64652	6266,65117	956,387378	434,727755	0,40322581	5000
16	4784,98481	4401,47687	5501,84608	1603,17413	769,54594	0,27454765	9375
17	3941,25923	7220,96037	5823,04997	933,376726	455,443821	0,38681918	5312,5
18	4036,36365	8458,72251	6506,70962	2120,9047	726,32354	0,24543148	8750
19	3618,65197	3860,65609	6434,42681	976,297427	449,244324	0,52725136	5312,5
20	3906,66201	4337,98968	4819,98853	1359,21215	597,446309	0,28369308	7187,5
21	3222,87578	6172,32636	5611,20578	1181,7631	589,419514	0,37985317	7031,25
22	3545,21889	3826,38131	4782,97664	1172,00145	683,043002	0,32648264	8281,25
23	4269,7603	6531,40294	5442,83578	1691,46944	602,602791	0,2574252	7187,5
24	3846,83469	3634,79914	4543,49892	1475,2897	633,346983	0,24637867	7656,25
25	2256,26196	4745,16749	5272,40833	917,399049	647,184444	0,45977011	7812,5
26	4203,04582	3081,49399	5135,82331	993,943038	581,233341	0,41336963	7031,25
27	4093,69403	7207,55371	6006,29476	965,62691	761,690279	0,4976079	9218,75
28	4100,36881	6411,39025	5342,82521	1490,48545	505,401449	0,28676967	5937,5
29	3436,04033	4665,40057	5183,77841	1108,23315	404,967737	0,37420129	4687,5
34	4059,49798	9408,7578	4951,97779	2110,91934	682,47432	0,18767094	8125
35	3078,01402	2977,82928	5955,65857	1275,45681	666,393842	0,37355454	8125
	3325,05735	8777,81015	5486,13134	1967,35577	630,68657	0,2230865	7500

## Cálculo índices Dependientes de la distancia.

Parcela	Staebler	Hegyí	Pukkala	Martin-Ek	Daniels	CCS
1	3,04	0,38377193	0,27142652	2,97289223	1,24607896	0,25496235
	8,56	0,73840142	0,39836244	11,4261769	0,48100436	1,33269378
	10,18	0,40071624	0,52036251	7,5220391	1,20739688	0,26894796
	15,36	1,09025912	1,09452036	15,6108102	0,45820305	1,50872461
2	20,27	0,76658768	1,04547545	16,8838039	0,58338092	0,9461847
	26,87	0,78056154	1,09867985	18,7380232	0,75083222	0,95172772
	12,83	1,46685637	1,23880759	14,5996426	0,37566702	2,66973098
3	13,12	1,69212282	1,09607988	21,8762504	0,24048793	1,29406447
	25,72	1,49731106	2,70914532	53,527159	0,46372333	1,30007343
	13,22	2,24703098	0,9662795	25,7263617	0,14750639	1,91970341
4	20,9	2,60182217	1,28539107	5877,61463	0,16073557	2,20273613
	35,51	0,83089308	1,64260768	447,001839	0,37709327	1,18198092
	10,88	1,84076986	0,50311429	31,6157409	0,14307786	1,80501172
5	28,29	1,4776234	1,26685592	91758,924	0,19988643	0,99521757
	16,93	1,38139676	1,72619033	17,7789294	0,44673435	1,29407213
	38,18	1,8888452	1,26132506	40,0259696	0,15166643	2,33207804
6	58,54	1,42207809	2,22078552	47,8270573	0,53618898	2,25550314
	17,61	1,31498578	1,49514214	17,7354408	0,45433329	1,7398934
	16,56	0,88029477	1,26805432	23,9119141	0,69480726	0,81812403
7	16,06	1,33640068	1,90177945	14,9620112	0,51072394	1,51488842
	28,88	0,88069427	2,31684749	153,858087	0,45732082	1,52391568
	10,77	1,74232465	1,39512035	16,3548424	0,38150306	3,38482487
8	22,43	1,73819052	2,15531747	76,3038214	0,44497248	3,28489736
	18,76	2,24983067	1,74691028	36,5326982	0,22231422	1,59729963
	16,96	1,27649824	0,97819178	27,9835146	0,31817675	1,63447068
9	21,34	2,1406244	1,55292471	718,056256	0,21778722	1,17883275
	27,74	1,67073435	1,8893554	371,472307	0,3307615	1,65951566
	15,86	1,31037362	0,99511387	30,2019216	0,28697711	2,1137975
10	19,82	1,86701122	1,14552294	41,7400293	0,17563306	1,27554444
	24	1,10396216	1,10615236	34,4568801	0,40024557	1,02315075
	19,3	1,13004441	1,06914581	16,3740352	0,50140111	1,90647372
11	18,56	1,23639381	1,51869772	15,224534	0,51832241	1,39371936
	27,72	1,22436275	1,38795501	33,119457	0,37613205	0,78338689
	23,04	1,70995532	1,59765092	26,421937	0,32019106	3,19894347
12	29,35	1,52534543	1,84625851	27,7040114	0,36329912	1,71418231
	29,48	0,99889901	1,36964566	25,902697	0,51003819	0,84112803

13 Modelado y Optimización del Manejo Silvicultural de la Producción de Madera de  
8 la Especie *Gmelina arborea* Roxb. en Colombia Mediante el uso de Técnicas de  
Inteligencia Computacional

	23,02	1,02537735	1,39130663	67,3110747	0,43601149	1,49330054
14	31,61	1,19081168	2,0757864	46,3909853	0,52175044	1,00259728
	28,22	2,15001623	1,00563932	133,145232	0,13067202	0,82040549
	17,79	1,12689203	0,97649034	22,7829418	0,35304734	2,66276889
15	31,68	1,82502161	1,46107513	507,801266	0,21783403	2,02438811
	34,87	1,4041762	1,44351156	218,968648	0,30196056	1,51764244
	23,44	2,38874661	1,31229711	159,664979	0,14687344	2,9296998
16	27,73	1,65126715	1,13842522	191,323058	0,20756242	2,14695784
	26,93	1,4312726	1,400536	113,50215	0,32678049	0,75424229
	26,82	2,39723166	1,24798727	90,0134048	0,11311679	3,86021171
17	27,28	1,70188002	0,9698225	1930,10878	0,21854845	2,29826575
	37,21	0,77287767	1,18847829	49,8776596	0,57093263	0,72387026
	22,73	2,36427875	1,24496136	91,1339803	0,14408278	2,4946652
18	20,18	1,59236884	0,96640884	41,3632002	0,23747158	2,46520967
	22,08	1,46186839	2,25419608	28,9839291	0,4858954	1,53138008
	26,21	2,0273124	1,6478221	149,957191	0,16574548	2,65489477
19	21,59	1,38396107	1,24083133	61,8131997	0,29182952	1,45689861
	23,88	0,85792504	1,06241926	44,2395194	0,68725876	0,97573255
	21,48	1,66489508	1,19236401	105,635555	0,20694904	2,37511993
20	15,81	1,12711307	1,04619246	65,1818235	0,40389607	2,50445163
	20,59	0,98735459	1,5040772	42,5463507	0,66850008	0,98787625
	19,45	2,05015424	1,55587927	69,2041515	0,16994931	1,91092542
21	20,88	1,30143077	1,25854032	44,3804072	0,38086754	1,37797
	5,14	1,14124653	1,26834128	22,2897074	0,53264453	1,0694766
	26,34	1,70486782	1,45587724	149,015901	0,23506804	2,26250169
22	25,59	1,73042754	34,2134263	124,084298	0,23573417	1,46896928
	24,05	1,18375144	2,18620266	34,5995588	0,56733967	1,02076279
	17,98	1,28094536	1,7453186	32,7347692	0,4738564	2,32101061
23	32,4	2,11315339	1,29870341	52,4468211	0,1828187	2,89340753
	32,34	0,90597538	1,56851965	196,445356	0,5542492	0,94980888
	23,79	1,39087578	1,25721182	55,8407036	0,42224578	2,54229714
24	23,03	2,04773476	1,31162686	1932,43838	0,22013663	2,15518839
	28,06	0,91951992	2,77126359	88,6251971	0,69558767	0,7674639
	23,46	1,48999441	1,78116665	56,1038914	0,37282712	2,57600674
25	21,72	1,97577825	2,04885418	46,0196208	0,36021563	2,03270254
	21,83	1,03873932	1,2525841	53,8942842	0,51247037	1,79125072
	28,18	1,7163565	1,18888357	352,59131	0,18863117	2,43482816
26	21,01	1,85002519	1,01597036	229,105535	0,19114023	2,17715114
	30,17	1,13215486	2,12540733	128,941719	0,41720409	0,6872174

---

	22,45	6,07168445	1,26201737	472,70729	0,02335899	5,90323276
27	25,15	1,6742354	1,52481448	71,2864081	0,25359033	1,42404284
	31,21	1,21837009	1,43777725	36,0818856	0,56981667	0,61839864
	30,3	1,17305598	1,09426757	47,1391274	0,35303964	1,98862992
28	21,47	1,6173256	1,06997158	66,6096217	0,25594012	1,42986694
	27,86	1,77944701	0,5104633	210,745313	0,10382054	0,62191081
	13,15	1,02019073	1,41099945	10,9224839	0,76752178	1,08392252
34	18,4	1,12685471	1,57437816	17,0680363	0,60780649	1,09590976
	24,26	1,95695487	2,2723458	49,409671	0,4629797	1,79902779
	11,91	1,20675013	0,67843291	1128,77024	0,25725175	0,74475052
38	23,36	1,22754698	1,06297786	98,9683451	0,25818002	2,18337111
	55,22	0,89506248	1,40859494	23,2217244	0,52784865	1,28062065

## ANEXO 2: CÓDIGO PRINCIPAL DEL AG

```
anios=input('Digite el número de años a calcular: ')
Pb=input('Digite el tamaño de la población: ')
Poblacn=Poblacion(Pb,anios);

for k1=1:60

    funcosto
    PobSelec1 = Seleccion(Poblacn,funcosto);
    HistPoblac(k1,:)=PobSelec1(1,:);
    PobSelec2= Torneo(Poblacn,funcosto);
    [B,idx1]= sort(funcosto,'descend');
    HistFcosto(k1)=B(1);
    PobNew=cruce(PobSelec1,PobSelec2,anios);
    Poblacn=mutacion(PobNew,anios);
end

fenotipo
```

## Anexo 3: Redes Neuronales con Python

Se implementaron cuatro modelos de RNA de tipo perceptrones multicapa sobre el conjunto de librerías para redes neuronales (framework) keras y Tensorflow.

El primero con una capa de entrada con 7 neuronas, una capa oculta con 70 neuronas con función de activación 'Relu' y una capa de salida de una neurona con función lineal ('linear').

Tabla 26. Arquitectura del primer modelo

Capa (tipo)	Salida	Función de activación	Param #
dense_1 (Dense)	(None, 70)	Relu	560
dense_2 (Dense)	(None, 1)	Linear	71

Total params: 631

Trainable params: 631

Non-trainable params: 0

El segundo modelo está compuesto por 7 neuronas, dos capa ocultas con 70 neuronas en cada capa con función de activación 'Relu' y una capa de salida de una neurona con función lineal

Tabla 27. Arquitectura del segundo modelo

Capa (tipo)	Salida	Función de activación	Param #
dense (Dense)	(None, 70)	Relu	560
dense_1 (Dense)	(None, 70)	Relu	4970
dense_2 (Dense)	(None, 1)	Linear	71

Total params: 5,601

Trainable params: 5,601

Non-trainable params: 0

La tercera RNA está compuesta por la capa de entrada de 7 neuronas, una primera capa oculta de 64 neuronas una segunda capa oculta de 70 neuronas, la tercera capa oculta nuevamente con 64 neuronas y la capa de salida con una neurona, con función de activación 'relu' en las tres primeras capas ocultas y función lineal en la capa de salida.

Tabla 28. Arquitectura del tercer modelo

<b>Capa (tipo)</b>	<b>Salida</b>	<b>Función de activación</b>	<b>Param #</b>
dense_1 (Dense)	(None, 64)	Relu	512
dense_2 (Dense)	(None, 70)	Relu	4550
dense_3 (Dense)	(None, 64)	Relu	4544
dense_4 (Dense)	(None, 1)	Linear	65

Total params: 9,671

Trainable params: 9,671

Non-trainable params: 0

Y la arquitectura de la cuarta RNA está compuesta por la capa de entrada de 7 neuronas, cinco capas ocultas, la primera con 14 neuronas y función de activación 'relu', la segunda y la cuarta de 70 neuronas cada una y función de activación 'relu', la tercera con 150 neuronas y función de activación 'relu', la capa oculta numero 5 con 7 neuronas y función de activación 'relu', y la capa de salida de una neurona con función de activación 'linear'.

Tabla 29. Arquitectura del cuarto modelo

<b>Capa (tipo)</b>	<b>Salida</b>	<b>Función de activación</b>	<b>Param #</b>
dense_1 (Dense)	(None, 14)	Relu	112

dense_2 (Dense)	(None, 70)	Relu	1050
dense_3 (Dense)	(None, 150)	Relu	10650
dense_4 (Dense)	(None, 70)	Relu	10570
dense_5 (Dense)	(None, 7)	Relu	497
dense_6 (Dense)	(None, 1)	Linear	8

Total params: 22.887

Trainable params: 22.887

Non-trainable params: 0

Para la selección de los mejores modelos matemáticos se consideró el estadístico: error cuadrático medio (ECM).

Se utilizó el mismo set de datos de entrenamiento y prueba para las cuatro redes utilizadas. Las estadísticas básicas de los datos se presentan en la siguiente tabla:

Tabla 30. Estadística de los datos de entrenamiento

	<b>Cantidad</b>	<b>Media</b>	<b>std</b>	<b>min</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>max</b>
Posición	2119	2,30203	0,97337	1	2	2	3	4
Edad	2119	5,29251	3,31607	1,46	3	3,9	7,5	15,5
Delta_Edad	2119	1,36790	0,90949	0,48	0,7	0,9	1,7	4,35
Diámetro	2119	13,88784	5,49475	1,6	10	13	17	33,7
Vecino	2119	6,92780	1,56477	1	6	8	8	8
IC	2119	1,92989	0,95616	0,17	1,4	1,8	2,2	10,7
IS	2119	21,10125	2,34949	16	19	22	23	24,6

El resultado del aprendizaje supervisado, que es el tipo de entrenamiento más utilizado para modelar funciones de estimación, dio los siguientes resultados:

### Red Neuronal de una sola capa oculta:

Resultados obtenidos

loss: 1.0470 - MAE: 0.7476 - MSE: 1.0470

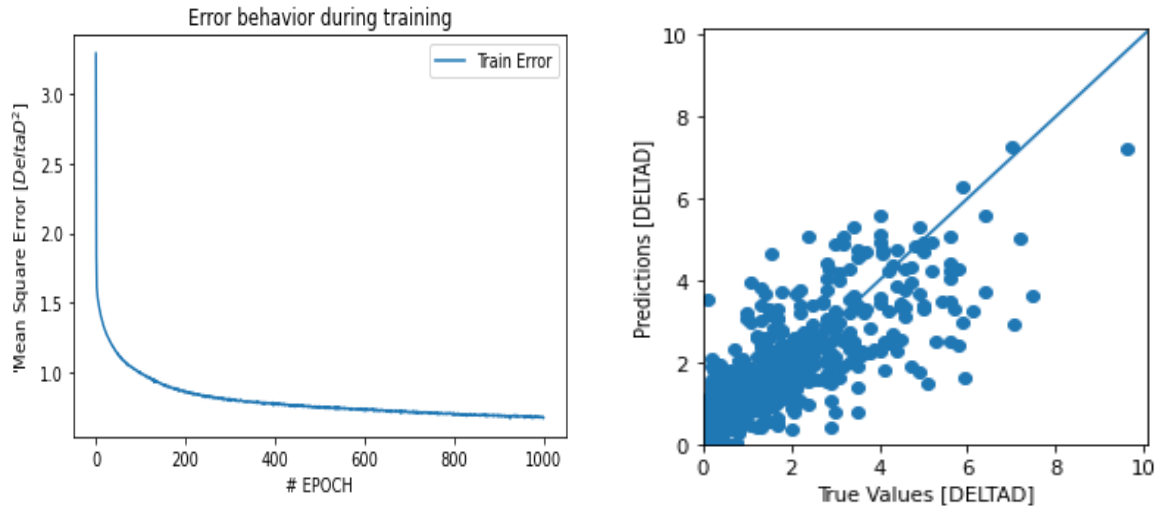


Figura 43. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de una sola capa oculta

### Red Neuronal de dos capas ocultas:

Resultados obtenidos

loss: 1.1472 - MAE: 0.7623 - MSE: 1.1472

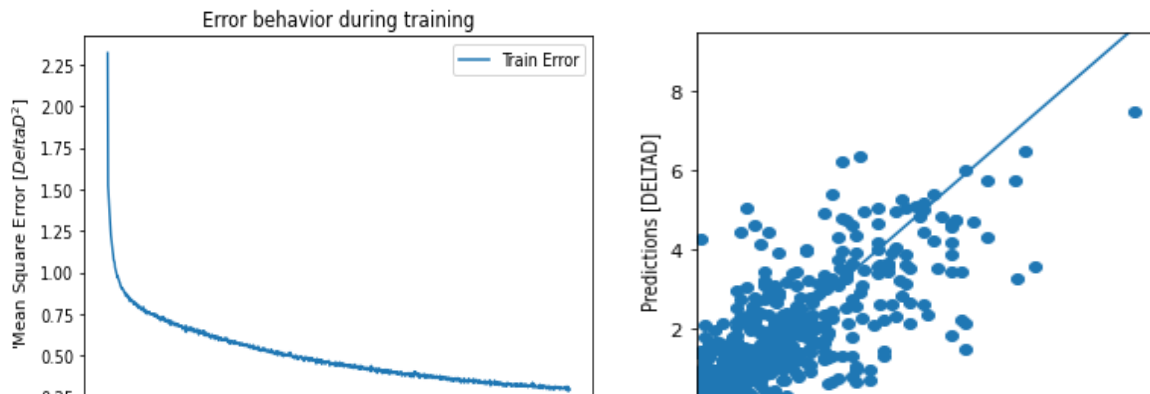


Figura 47 Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de dos capas ocultas

**Red Neuronal de tres capas ocultas:**

Resultados obtenidos

loss: 1.0764 - MAE: 0.8068 - MSE: 1.0764




Figura 48. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal de tres capas ocultas

**Red Neuronal profunda (7 capas):**

Resultados obtenidos

loss: 1.1832 - MAE: 0.7774 - MSE: 1.1832

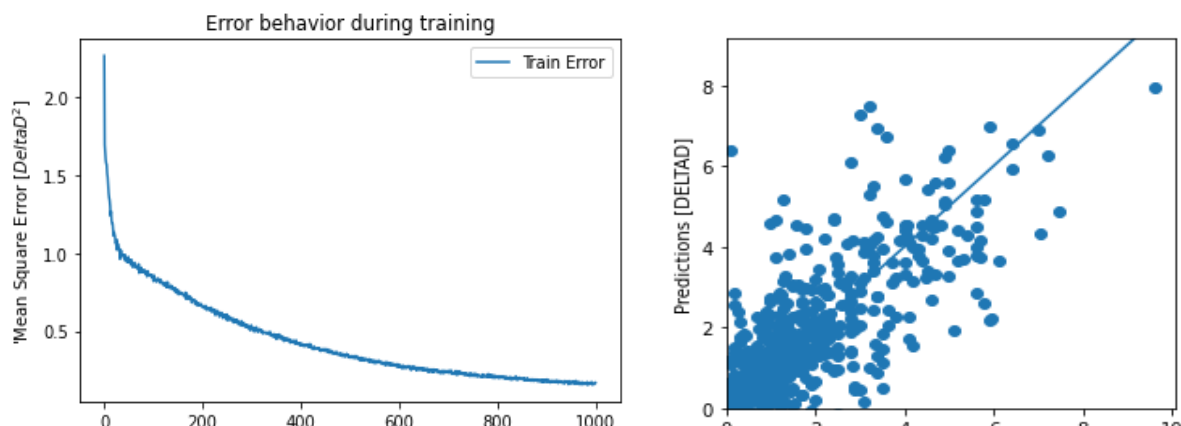


Figura 49. Descripción del comportamiento del error y de la relación de los valores reales y predichos de la red neuronal profunda (7 capas)

### Modelo de Validación

En la siguiente tabla se presentan los resultados obtenidos de los modelos estadísticos (ecuaciones (3.4), (3.5) y (3.6)).

Tabla 31. Resultados obtenidos del modelo estadístico (ecuaciones (3.4), (3.5) y (3.6))

Ecuación	Observaciones	Parámetros	Error DF	ECM	R <sup>2</sup>	R <sup>2</sup> adjus
(3.4)	2649	6	2643	0.9472	0.4553	0.4542
(3.5)	2649	7	2642	0.9223	0.4698	0.4698
(3.6)	2649	7	2642	0.9401	0.4595	0.4583

**Leyenda:** donde R<sup>2</sup> es el coeficiente de determinación del modelo y EMC es el error medio cuadrático del modelo.

Para efectos de comparación y validación, se corrió nuevamente el modelo estadístico de la ecuación (3.5), que presenta los mejores indicadores, con los datos de entrenamiento de la red para que la comparación se realice con los mismos datos, obteniendo los resultados presentados en la Tabla 18.

Tabla 32. Resultados obtenidos de los datos de entrenamiento

Variable	DF	Estimador del parámetro	Error estándar	t	Pr> t	ECM	R <sup>2</sup>	R <sup>2</sup> adjus
Intercepto	1	2.30086	0.64361	3.57	0.0004	0.9575	0.4614	0.4598
Edad	1	-1.38771	0.06756	-20.54	<.0001			
Delta_ Edad	1	0.72995	0.03650	20.00	<.0001			
Diámetro	1	0.29000	0.10180	2.85	0.0044			
Vecino	1	0.47622	0.11158	4.27	<.0001			
IC	1	-0.76635	0.09902	-7.74	<.0001			
IS	1	-0.48503	0.23136	-2.10	0.0362			

Para tener un valor equivalente del Error Medio Cuadrático del modelo alométrico , con los valores obtenidos en los modelos de RNA, se corrió el modelo alométrico con los datos de test con los que se calcularon los valores de ECM de las cuatro RNA. Igualmente, cada arquitectura

de red fue entrenada con el conjunto de datos incluyendo la competencia y sin incluirla, ver Tabla 19.

Tabla 33. Comparación de los valores de ECM de los modelos

<b>Modelo</b>	<b>ECM - Competencia</b>	<b>ECM – Sin Competencia</b>
Red neuronal de una sola capa oculta	1.0470	1.1330
Red neuronal de dos capas ocultas	1.1472	1.2356
Red neuronal de tres capas ocultas	1.0764	1.2529
Red neuronal profunda (7 capas)	1.1832	1.2477
Modelo estadístico (Validación)	1.5267	

Los resultados muestran que la red de una sola capa, para resolver modelos de regresión, presenta los mejores resultados, siendo la red de una sola capa con y sin competencia mejor que las demás, y sólo la red de tres capas obtuvo un mejor resultado incluyendo la competencia que la capa de una sola red que no incluía la competencia. La red neuronal que incluye la competencia siempre obtuvo mejores resultados que la red neuronal que no la incluía.

Del estudio de densidad, a partir del Índice de Densidad del Rodal (IDR) se muestra como el coeficiente  $b$  de la ecuación 1.1 es propio de la especie y se deberá calcular para cada especie a partir de los rodales en condición de autorraleo. De la misma manera el cálculo del  $IDR_{Max}$ , permitirá determinar las zonas de densidad (figura 2) y por ende la necesidad de un raleo cuando la densidad alcance la zona 4.

De la revisión de los modelos lineal (3.1), exponencial (3.2) y potencial (3.3), se encontró que índice de competencia dependiente de la distancia de Hegyi, como se corrobora en (Álvarez-Taboada, Barrio-Anta, Gorgoso Varela, et al., 2003), se destaca en casi todos los tres modelos, y por ser calculado a partir de los diámetros normales, se considera el índice adecuado para incluir en los modelos de Red Neuronal.

Se probó que la red neuronal de una sola capa propuesta por el software MatLab para el estudio de regresión es muy eficiente. Para ello se implementaron varias redes en Python con más capas ocultas y suficientes neuronas en cada capa y los mejores estadísticos los presentó la red de una sola capa (ver Anexo 3).

De la misma manera, se muestra que incluir los índices de competencia en los modelos linealizados logarítmicamente (7) y (8), mejora el resultado de los estadísticos de correlación, demuestra que al incluir el Índice de competencia y los vecinos de cada árbol, en el modelo, permite simular el proceso de manera más eficiente.

La implementación de la Red Neuronal Artificial evidencia que esta es efectivamente capaz de mejorar el estadístico ECM y los valores de regresión R, específicamente el modelo de red de una sola capa. Por lo tanto, este modelo explica eficientemente el comportamiento de crecimiento de los rodales de *Gmelina arborea* Roxb en la región del Tolima, mostrando las ventajas de la inclusión de la competencia en el modelo. Además, se apoya en variables básicas como su edad, índice de sitio, diámetro normal y el diámetro de los árboles vecinos con los que compiten por los recursos.

Ver una plantación como una red de autómatas celulares, permite elevar el modelo de árbol individual, implementado en la red neuronal, a nivel de modelo de rodal, trayendo como ventaja la inclusión de la competencia intraespecífica al modelo.

Para el manejo del raleo, la literatura muestra que se implementan ensayos forestales que, por su naturaleza, requieren mucho tiempo para obtener los resultados deseados, se encontró que a partir de estos ensayos se agregan ya sea por adición o multiplicación ecuaciones a los modelos alométricos como intentando corregir las modificaciones a los parámetros por efecto de esta intervención. En razón a que el modelo propuesto de manejo de rodal (autómatas celulares) incluye la competencia, intrínsecamente se asumen los efectos del raleo.

La ventaja de la metodología propuesta, está en el uso del algoritmo genético como una herramienta de optimización que permitirá planificar con mayor precisión el componente esencial en el manejo de la silvicultura, como lo es el raleo.

Para la validación de la metodología propuesta, los resultados obtenidos fueron comparados con los resultados del simulador SimFor que incluye corrección de parámetros en los tiempos de raleo, al cual se le entregaron los tiempos y los datos de intensidad de raleo propuestos en este trabajo como resultado del algoritmo genético, obteniendo valores similares.

Se considera entonces que el modelo y la metodología propuesta logran una buena aproximación al comportamiento de los rodales de *Gmelina arborea* Roxb., así como una buena estrategia de raleo, a la que habría que adicionar un estudio de costos del desarrollo de este proceso.

Una implementación masiva de esta metodología en la planificación silvícola contribuiría a la estabilidad de la industria y a partir de la expansión de los bosques plantados, conservar la biodiversidad, los servicios ecosistémicos y mitigar el impacto del cambio climático.

#### Recomendaciones

Mejorar los valores de IS- con la ayuda de un nuevo estudio que realiza el grupo Maderas y Bosques, a partir de condiciones de suelo humedad temperatura y precipitación.

Analizar soluciones económicamente eficientes para contribuir a la comprensión de las decisiones económico-silvícolas, (la teoría de la inversión proporciona un marco teórico (Koster & Fuchs, 2022) )

Para efectos de eliminar un poco las diferencias de crecimiento encontradas en las mediciones es indispensable agregar la variable climática de precipitación de la cual se puede obtener un registro histórico mensual para algunas regiones próximas a los rodales estudiados.

La Universidad del Tolima tiene una nueva plantación de *Gmelina* en la granja de Armero y además otra especie, *Tectona grandis* en donde se pretende establecer parcelas permanentes, especies con las cuales también se podría aplicar toda la metodología utilizada en este trabajo.

El software utilizado para la implementación de las herramientas es un sistema propietario de alto costo que difícilmente una empresa forestal quiera asumir, por lo cual ya se está trabajando, con estudiantes del programa de Ingeniería de Sistemas, en la implementación en el lenguaje de alto nivel Java.

Llevar los valores obtenidos de tiempo de raleo e intensidad al diagrama de Hart-Beiking de forma automatizada, como otra forma de mostrar los resultados.

Por otro lado, se recomienda continuar con los estudios económicos-silvícolas con base en las propuestas por Koster y Fuchs (2022).

Queda como tarea la implementación del Algoritmo de Levenberg-Marquardt como metodo de retropropagación de una RNA – Python