

Proyección de supervivencia en plantaciones de *Pinus caribaea* Morelet var. *caribaea* Barrett & Golfari

Survival prognosis in plantations of *Pinus caribaea* Morelet var. *caribaea* Barrett & Golfari

Ouorou Ganni Mariel Guera¹

José Antônio Aleixo da Silva¹

Rinaldo Luiz Caraciolo Ferreira¹

Daniel Álvarez Lazo²

Héctor Barrero Medel²

¹Universidad Federal Rural de Pernambuco (UFRPE), Departamento de Ciência Florestal (DCFL), Laboratório de Biometria e Manejo Florestal (LBMF). Brasil. Correo electrónico: gueraforest@gmail.com; jaaleixo@gmail.com; rinaldo.ferreira@ufrpe.br
²Ingeniero Forestal. Universidad de Pinar del Río «Hermanos Saíz Montes de Oca», Facultad de Ciencias Forestales y Agropecuaria Departamento Forestal. Cuba. Correo electrónico: daniel@upr.edu.cu; hbarrero@upr.edu.cu

Recibido: 2 de noviembre 2017.

Aprobado: 30 de enero 2018.

RESUMEN

El presente estudio fue realizado con el objetivo de obtener ecuaciones de regresión y Redes Neuronales Artificiales (RNAs) para la proyección de la supervivencia de *Pinus caribaea* var. *caribaea* en la empresa forestal Macurije, provincia de Pinar del Río, Cuba. Los datos utilizados en las modelaciones provienen de la medición de las variables edad (años) y supervivencia (densidad) en parcelas permanentes circulares de 500 m², establecidas en plantaciones de *P. caribaea* var. *caribaea*. El estudio se dividió en tres etapas: 1) Ajuste de modelos de regresión tradicionales para proyección de supervivencia; 2) Entrenamientos de RNAs para la

proyección de supervivencia, incluyendo variables categóricas «sitio» y «Unidades Básicas de Producción Forestal»; 3) Comparación de los desempeños de las ecuaciones de regresión con los de las RNAs en la proyección de la supervivencia. Los mejores modelos y RNAs fueron seleccionados y basados en: coeficiente de determinación ajustado -R²_{aj} (%), raíz cuadrada del error medio cuadrático - RMSE (%) y análisis de distribución de residuos. La evaluación de la bondad de ajuste de los modelos también incluyó la verificación de los supuestos de normalidad, homocedasticidad y ausencia de autocorrelación serial en

los residuos por las pruebas de Kolmogorov-Smirnov, White y Durbin-Watson, respectivamente. El modelo de Pienaar y Shiver de 1981 resultó ser el de mejor ajuste en la proyección de la supervivencia. La RNA de

arquitectura MLP 13-10-1 fue la de mejor capacidad de generalización y presentó un desempeño similar al de la ecuación obtenida del ajuste del modelo de Pienaar y Shiver.

Palabras clave: Plantaciones forestales; mortalidad regular; regresión no lineal; Redes Neuronales Artificiales.

ABSTRACT

The present study was carried out with the objective of obtaining regression equations and Artificial Neural Networks (ANNs) for the prognosis of *Pinus caribaea* var. *caribaea* survival in Macurije Forest Company, province of Pinar del Río - Cuba. The data used in the modeling comes from the measurement of the variables age (years) and survival (density) in circular permanent plots of 500 m² established in *P. caribaea* var. *caribaea* plantations. The study was divided into three stages: i) Adjustment of survival traditional regression models; ii) Training of ANNs for survival prognosis, including categorical variables «site» and «Basic Units of Forest Production»; iii) Comparison of regression equations performance with

those of ANNs in survival prognosis. The best models and ANNs were selected based on: adjusted determination coefficient - R^2_{aj} (%), square root of the mean square error - RMSE (%) and residue distribution analysis. The evaluation of the models goodness of fit also included the verification of the assumptions of normality, homocedasticity and absence of serial autocorrelation in the residues by Kolmogorov-Smirnov, White and Durbin-Watson tests, respectively. The model of Pienaar and Shiver 1981 turned out to be the best fit in survival prognosis. The ANN MLP 13-10-1 was the one with the best generalization capacity and presented a performance similar to that of Pienaar and Shiver equation.

Keywords: Forest plantations; regular mortality; nonlinear regression; Artificial Neural Networks (ANNs).

INTRODUCCIÓN

La mortalidad de árboles es uno de los principales elementos de la dinámica forestal Bigler, (2003). La misma, como variable complementaria de la supervivencia, puede ser definida como la reducción de la densidad de un bosque o de una plantación, ocasionada por factores naturales Sanquetta, (1990). Según Campos y Leite (2017), este fenómeno (la mortalidad) no debe confundirse con las fallas de siembra que ocurren en la

etapa inicial del establecimiento de las plantaciones y que pueden ser repuestas. Descuidar la mortalidad, como sucede generalmente en los estudios de crecimiento y producción forestal, es aceptable solo en plantaciones forestales industriales intensamente manejadas Vanclay, (1991), principalmente, si los raleos periódicos están incluidos dentro de los tratamientos forestales aplicados Campos y Leite, (2017).

Aunque este componente de crecimiento sea implícito en los modelos de proyección de crecimiento y producción forestal, su modelación se realiza de forma explícita para obtener ecuaciones de auxilio a la toma de decisiones relacionadas con las densidades de los rodales. En dependencia de la fuente de los factores naturales al que hace referencia Sanquetta (1990), Lee (1971) distingue dos tipos de mortalidad: la mortalidad regular, característica de plantaciones muy maduras y densas, es atribuida a factores intrínsecos, a los árboles como la senescencia, la genética y la alta competencia por recursos naturales limitados; y la mortalidad irregular, causada por factores no intrínsecos al árbol como incendios, plagas y enfermedades, vientos y daños mecánicos. La complejidad de la previsión de los factores causantes de la mortalidad irregular dificulta su proyección, por lo que la mayoría de los estudios se enfocan en la mortalidad regular, interés del presente estudio.

Numerosos métodos de proyección de mortalidad regular se desarrollaron para los bosques monoespecíficos (plantaciones puras) Vanclay, (1991). Los mismos son generalmente propuestos al nivel de plantación o de árbol individual Thapa, (2014). Los modelos al nivel de plantación se basan en la edad y densidad inicial del rodal y los desarrollados al nivel de árbol individual se basan, generalmente, en la probabilidad de mortalidad de cada árbol o grupo de árboles. Las variables dependientes de estos modelos son: el número de árboles por hectárea (N/ha.), como en los modelos desarrollados por Clutter y Jones (1980), Pienaar y Shiver (1981) o Silva y Bailey (1986) que proyectan la supervivencia (variable complementaria de la mortalidad) al nivel de plantación y la probabilidad de mortalidad de los árboles como en el enfoque propuesto por Hamilton (1974) al nivel de árboles individuales y la tasa anual de supervivencia por

clase diamétrica como en el enfoque de Buchman *et al.* (1983) para grupos de árboles.

Entre los modelos, generalmente no lineales, propuestos para la modelación de la supervivencia (o mortalidad) al nivel de plantación, se pueden destacar los de Clutter y Jones (1980), Pienaar y Shiver (1981) y Silva y Bailey (1986) que se han mostrado adecuados y eficientes para el análisis del fenómeno en numerosos estudios. Según Clutter *et al.* (1983), todo modelo adecuado para la proyección de mortalidad debe tener las siguientes propiedades: (1) Si la edad final (I_2) es igual a la edad inicial (I_1), la densidad o supervivencia final (N_2) debe ser igual a la densidad o supervivencia inicial (N_1); (2) Para rodales coetáneos, cuando I_2 es muy avanzada, N_2 debe aproximarse a cero; (3) Si el modelo se utiliza para proyectar N_2 en la edad I_2 , y I_2 y N_2 se utilizan para proyectar N_3 a una edad I_3 ($I_3 > I_2 > I_1$), el resultado debe ser igual a la proyección directa de I_1 a I_3 .

La importancia de la proyección precisa de la mortalidad en los sistemas de crecimiento y producción forestal es irrefutable; pero la mortalidad sigue siendo uno de los componentes menos comprendidos debido a la complejidad de los ecosistemas forestales Hamilton, (1986) y, debido a lo mismo, es el componente de crecimiento forestal más difícil y menos confiable de estimar Glover y Holl, (1979).

En las últimas décadas, buscando estimaciones más precisas, técnicas como las de Redes Neuronales Artificiales (RNAs) fueron ampliamente utilizadas en el sector forestal, con resultados satisfactorios. Según Haykin (2007), las redes neuronales artificiales son procesadores constituidos por unidades de procesamiento simple, que tienen la propensión natural para almacenar conocimiento experimental y hacer que esté disponible para su uso. Con el fin de una mejor comprensión de la mortalidad de los árboles y el

desarrollo de modelos con mejores capacidades predictivas, numerosas investigaciones utilizaron las RNAs para la modelación de la mortalidad o supervivencia de los árboles Guan y Gertner, (1991), King *et al.*, (2000).

Teniendo en cuenta lo anterior, el presente estudio tuvo como objetivo: ajustar modelos de regresión no lineal y entrenar RNAs para la proyección de la supervivencia en plantaciones de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf., en la Empresa Forestal Integral (EFI) Macurije, Pinar del Río, Cuba.

MATERIALES Y MÉTODOS

Ubicación del área de estudio

La presente investigación fue desarrollada en plantaciones de *Pinus caribaea* var. *caribaea* de la Empresa Forestal Integral (EFI) Macurije, ubicada aproximadamente entre las

coordenadas geográficas 22° 06' a 22° 42' latitud norte y 83° 48' a 84° 23' longitud oeste, en la región más occidental de la provincia de Pinar del Río, Cuba (Figura 1).

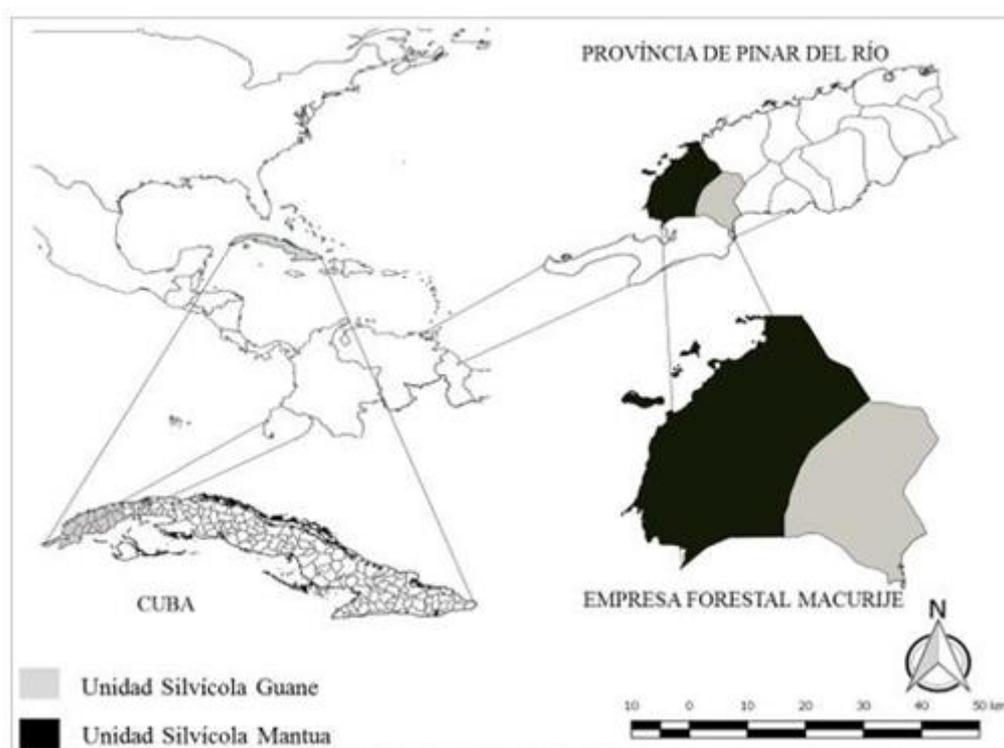


Fig.1 Localización geográfica de la Empresa Forestal Macurije, Pinar del Río, Cuba.

Fuentes de datos para la modelación de la supervivencia

Los datos fueron obtenidos de 14 parcelas permanentes de 500 m² (r = 12,615 m.), distribuidas en las dos unidades silvícolas (Guane y Mantua) y cinco unidades básicas de producción forestal (Los Ocujes, Las Cañas, Sábalo, Río Mantua y Macurije) de la Empresa Forestal Integral (EFI) Macurije. Las mismas cuentan con mediciones de las variables diámetro a

altura de pecho (cm.), altura total (m.) y supervivencia (número de árboles/ha.) en diferentes edades (I). Los modelos de supervivencia se basaron y utilizaron, como variable dependiente, la densidad futura (N₂) y como variables independientes la densidad inicial (N₁) y las edades presentes (I₁) y futuras (I₂).

Modelos de proyección de supervivencia en plantaciones de *P. caribaea* var. *caribaea* en la EFI Macurije

La literatura forestal cuenta con varios modelos desarrollados para la proyección de la supervivencia/mortalidad en plantaciones forestales. Entre

aquellos, que presentaron buenos ajustes a lo largo de numerosos estudios empíricos, fueron seleccionados y ajustados los de la tabla 1 (Tabla 1).

Tabla 1. Modelos de estimación de la supervivencia futura en plantaciones de *Pinus caribaea*

Nº	Autores	Expresiones matemáticas	Fuentes
1	Clutter & Jones (1980)	$N_2 = \left[N_1^{\beta_0} + \beta_1 (I_2 - I_1^{\beta_2}) \right]^{\frac{1}{\beta_0}} + \varepsilon_i$	Sanquetta (1990)
2	Silva & Bailey (1986)	$N_2 = N_1 e^{\beta_0(\beta_1^{I_2} - \beta_1^{I_1})} + \varepsilon_i$	Silva (1986)
3	Pienaar & Shiver (1981)	$N_2 = N_1 e^{-\beta_0(I_2^{\beta_1} - I_1^{\beta_1})} + \varepsilon_i$	Campos & Leite (2017)
4	Chapman & Richards (1959)	$N_2 = N_1 \left[\frac{1 - e^{\beta_0 I_2}}{1 - e^{\beta_0 I_1}} \right]^{\beta_1} + \varepsilon_i$	Silva (2015)
5	Weibull	$N_2 = N_1 - \beta_0 \left[e^{-\beta_1 I_2^{\beta_2}} - e^{-\beta_1 I_1^{\beta_2}} \right] + \varepsilon_i$	Silva (2015)

En que: N₂ = Número de árboles en el futuro; N₁ = Número de árboles en el presente; I₂ = Edad futura; I₁ = Edad presente; β_i = Parámetros a ser estimado en el ajuste.

El ajuste de los modelos, así como el entrenamiento de las RNAs, abordado en la próxima sección, se realizó con el software STATISTICA vers. 8. Los modelos de supervivencia (Tabla 2)

fueron ajustados por medio de los métodos iterativos de Levenberg-Marquardt, Gauss-Newton o Newton-Raphson en dependencia de la convergencia de los mismos.

Entrenamiento de Redes Neuronales Artificiales para la proyección de la supervivencia en plantaciones de *Pinus caribaea* var. *caribaea*

Se procedió al entrenamiento de 100 Redes Neuronales Artificiales (RNAs) de los tipos Multi-Layer Perceptron (MLP) y Radial Basis Function (RBF) para la proyección de supervivencia a nivel de plantación, y las mejores RNAs fueron retenidas para análisis. La supervivencia futura (N_2) fue proyectada a partir de la densidad actual (N_1) de las edades presentes (I_1) y futuras (I_2) y del índice de sitio (S). El algoritmo de entrenamiento utilizado fue el Broyden-Fletcher-

Goldfarb-Shanno (BFGS), conocido por su mayor tasa de convergencia y capacidad de búsqueda más inteligente. Durante los entrenamientos, las funciones de activación probadas en las neuronas ocultas o de salida fueron las funciones Identidad (Expresión 01), Logística (Expresión 02), Exponencial (Expresión 03) y Tangente hiperbólica (Expresión 04) para las RNAs del tipo MLP.

$$\phi_i(x) = x \quad (01)$$

$$\phi_i(x) = \frac{1}{1 + e^{-\beta x}} \quad (02)$$

$$\phi_i(x) = \text{Exp}(\beta x) \quad (03)$$

$$\phi_i(x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}} \quad (04)$$

Para las Redes Neuronales Artificiales del tipo RBF, las funciones de activación probadas fueron: la de base Gaussiana (Expresión 05) y la de base Multi-quadrática (Expresión 06).

$$\phi_i(x) = \text{Exp}\left[-\frac{\|x_j - \mu_i\|^2}{2\sigma_i^2}\right] \quad (05)$$

$$\phi_i(x) = \sqrt{\|x_j - \mu_i\|^2 + \sigma_i^2} \quad (06)$$

En que: $\phi_i(x)$ = Función de activación; x = media ponderada entre los ejemplos de entrada y el conjunto de pesos de las RNAs; x_j = ejemplos de entrada de las RNAs; μ_i y σ_i representan respectivamente el centro y la dispersión de la i -ésima función de base radial.

El uso de variables cualitativas o categóricas es una de las grandes ventajas de las Redes Neuronales Artificiales. Por ello, dos variables dummies fueron incluidas en los entrenamientos: la variable «índice de sitio» para la realización de las predicciones por clase de sitio y la variable «UBPF» para posibilitar la realización de las predicciones de supervivencia por Unidad Básica de Producción Forestal (UBPF). Las categorías de esta última variable son las cinco UBPFs de la Empresa: Los Ocujes, Las Cañas, Sábalo, Río Mantua

y Macurije. Los datos de las clases de sitios fueron obtenidos, a partir de las curvas polimórficas de índice de sitio, propuestas para el área de estudio. Ambas variables categóricas fueron codificadas y normalizadas por medio del procedimiento 1-de-N.

Para los entrenamientos, la base de datos fue dividida, siguiendo estas proporciones: 50 % para el entrenamiento, 25 % para la evaluación del desempeño de la red y 25 % para la validación cruzada, criterio de parada del entrenamiento

de la RNA. Para mejorar la eficiencia (convergencia estable de los pesos y desvíos) del algoritmo de entrenamiento que puede verse afectado por la variación de las escalas de las variables, los datos fueron

$$y = \frac{(b - a)(x_i - x_{min})}{(x_{max} - x_{min}) + a} \quad (07)$$

En que: y es el valor normalizado; x_i es el valor original; x_{min} es el valor mínimo de la variable; x_{max} es el valor máximo de la variable; a e b son los límites del intervalo de normalización.

Para un mejor entendimiento de la relación entre las variables de entradas de las RNAs y, principalmente, su importancia en la predicción de la supervivencia, fue realizado un análisis

$$Cont_j(\%) = \frac{\sum_{n=1}^N Sen_{jn}^2}{\sum_{j=1}^{N_{inp}} \sum_{n=1}^N Sen_{jn}^2} \quad (08)$$

Siendo:

$$Sen_{jn} = \sum_{k=1}^{N_{hid}} W_{kj} \cdot f'(net_k) \cdot \sum_{l=1}^{N_{out}} W_{lk} \cdot f'(net_l) \cdot e_l(n) \quad (09)$$

En que: $Cont_j(\%)$ = Contribución porcentual de cada variable; Sen_{jn} = sensibilidad de cada variable de entrada j ($j = 1, \dots, N_{inp}$) en relación con la variable de salida para un determinado ejemplo n ($1, \dots, N$); N_{inp} representa el número total de neuronas o variables en la capa de entrada; N_{out} representa el número de neuronas en la capa de salida. W_{kj} son los pesos sinápticos que conectan la capa escondida a la capa de entrada y W_{lk} son los que conectan la capa de salida a la capa escondida. $f'(net_l)$ y $f'(net_k)$ son las derivadas de las funciones de activación de las neuronas de las capas de salida y escondida respectivamente; $e_l(n)$ es el error en la capa de salida.

Criterios de evaluación y selección de los modelos

Los desempeños de los modelos de regresión y de las RNAs fueron evaluados sobre la base de coeficiente de determinación ajustado - (Expresión 10), raíz cuadrada del error medio cuadrático - RMSE (%) (Expresión 11), Sesgo (Expresión 13) y análisis de distribución de residuos (Expresión 12) para análisis de posibles tendencias de estimación (sesgos) en las ecuaciones o RNAs obtenidas.

normalizados y escalados en los intervalos $[0,1]$ o $[-1,1]$, en dependencia de la función de activación, utilizando una transformación lineal (Expresión 07).

sensibilidad. La contribución porcentual de cada variable fue calculada con las expresiones 08 y 09.

La evaluación de los modelos de regresión fue basada, también, en la satisfacción de los supuestos de normalidad, homocedasticidad y ausencia de autocorrelación serial en los residuos verificados por las pruebas de Kolmogorov-Smirnov, White y Durbin-Watson, respectivamente.

$$R_{aj}^2 = R^2 - \left[\frac{N-1}{N-K} \right] * (1 - R^2) \quad (10)$$

En que: R^2 = Coeficiente de determinación; K = número de parámetros; N = número de observaciones.

$$RMSE(\%) = 100 \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} / \bar{Y} \quad (11)$$

En que: Y = Densidad observada (número de árboles/ha.); \hat{Y} = Densidad estimada (número de árboles/ha.); \bar{Y} = media de las densidades observadas; n = número de observaciones.

$$E_i = \frac{(Y_i - \hat{Y}_i)}{Y_i} * 100 \quad (12)$$

En que: E_i = Residuo de la i -ésima observación; Y_i = Valor observado de la variable dependiente; \hat{Y}_i = Valor de la variable dependiente estimado por la ecuación o la RNA.

$$Sesgo = n^{-1} \sum_{i=1}^n (Y_i - \hat{Y}_i) \quad (13)$$

En que: Y = Valor observado de la variable dependiente; \hat{Y} = Valor de la variable dependiente estimado por la ecuación o la RNA; n = número de observaciones.

Como reglas de decisión, se consideró que los mejores modelos fueron aquellos que, además de presentar mayores R_{aj}^2 , menores RMSE (%) y una dispersión de residuos sin sesgo y en torno a cero, satisfagan todos los supuestos anteriormente citados.

La comparación del desempeño del modelo de mejor ajuste con el de la RNA seleccionada fue realizada con la prueba t para datos pareados.

RESULTADOS Y DISCUSIÓN

Modelos de proyección de supervivencia futura en plantaciones de *Pinus caribaea*

Los resultados de los ajustes de los modelos de supervivencia (tabla 2) indicaron buenos ajustes con todos los R^2 mayores que 97 % y RMSE menores que 5 %. Sin embargo, los valores de los Sesgos y los gráficos de distribución de residuos (figura 2) indicaron que las

proyecciones menos sesgadas fueron obtenidas con la ecuación de Pienaar y Shiver (1981). En coherencia con Silva (2015), los modelos de Silva y Bailey (1986) y Chapman-Richards Chapman, (1961); Richards, (1959) presentaron desempeños similares.

Tabla 2. Estimativas de los parámetros de los modelos de proyección de supervivencia en plantaciones de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf.

Nº	MODELOS	Estimativas dos parámetros			R ² (%)	RMSE (%)	Sig.	Sesgo (%)
		β_0	β_1	β_2				
1	Clutter & Jones (1980)	9,491*	8,762*	7,144*	97,3 3	4,21	0,0 0	-7,35
2	Silva & Bailey (1986)	0,063*	394,290*	-	97,5 5	3,94	0,0 0	-6,19
3	Pienaar & Shiver (1981)	1,27E-06*	3,034*	-	97,5 2	3,01	0,0 0	-1,50
4	Chapman & Richards (1959)	-2,877*	- 540,844*	-	97,5 4	3,94	0,0 0	-6,20
5	Weibull	- 245939,49*	-35,366*	- 10,578*	97,5 4	3,97	0,0 0	-6,21

*Estimativa del parámetro significativa a 99 % de probabilidad por la prueba t.

Los resultados de las pruebas de Kolmogorov-Smirnov indicaron que solo los residuos de los modelos de Silva y Bailey (1986) y Pienaar y Shiver (1981) siguieron una distribución normal, con p-valores de 0,053 y 0,068, respectivamente. En cuanto a la prueba de Durbin-Watson, sus resultados indicaron que los modelos que presentaron residuos libres de autocorrelación serial fueron los de Clutter y Jones (1980), Silva y Bailey (1986) y Pienaar y Shiver (1981) con la estadística DW igual a 1,700, 1,762 e 1,718, respectivamente. Los

modelos de Chapman-Richards y de Weibull, además de presentar residuos con autocorrelación serial positiva, fueron los únicos que no atendieron el supuesto de homocedasticidad.

La satisfacción de todos los supuestos en el modelo preseleccionado (Pienaar y Shiver) favoreció su selección definitiva para la proyección de supervivencia en las plantaciones de *Pinus caribaea* var. *caribaea* de la empresa forestal Macurije.

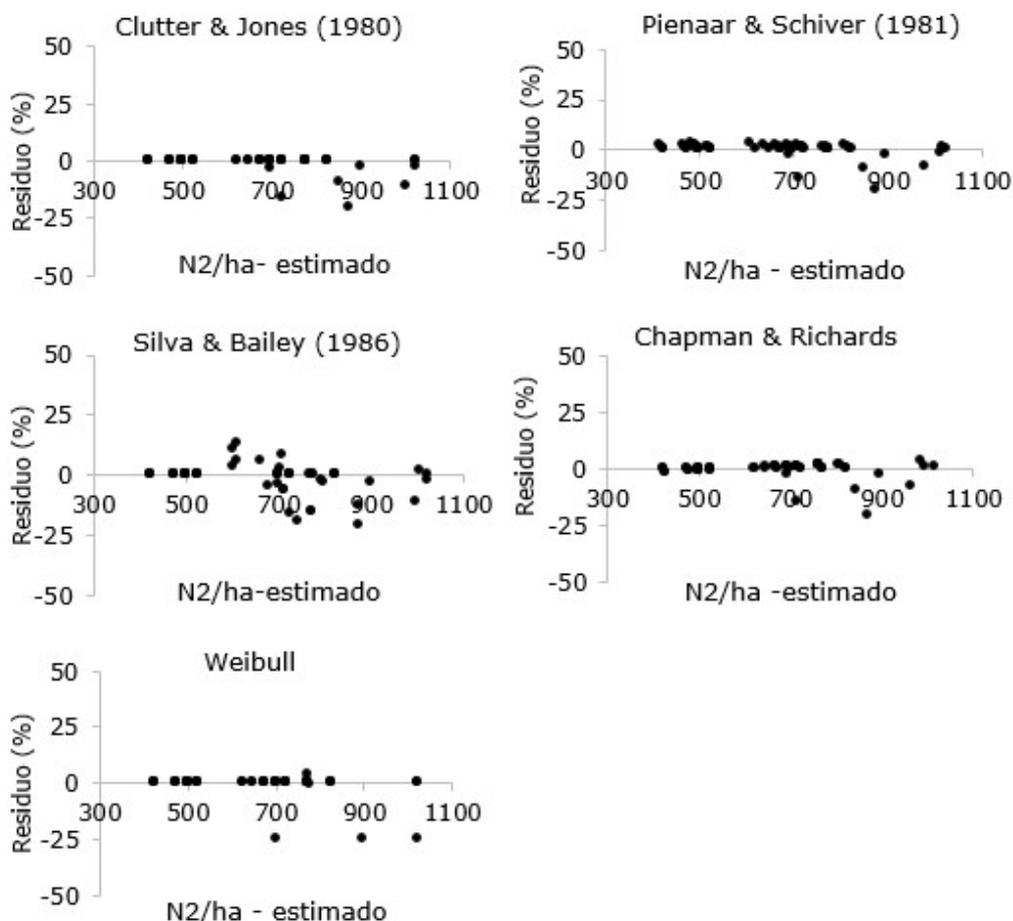


Fig. 2 Distribución de residuos de los modelos de predicción de supervivencia en plantaciones de *Pinus caribaea* var. *caribaea* de la empresa forestal Macurije.

Las proyecciones de supervivencia/mortalidad para diferentes densidades iniciales en las plantaciones de *Pinus caribaea* var. *caribaea* por medio de la ecuación de Pienaar y Schiver generaron resultados consistentes (Figura 3). Se

observaron, para mayores densidades iniciales (N_1), una mayor inclinación de la curva, consecuencia de una mayor tasa de mortalidad.

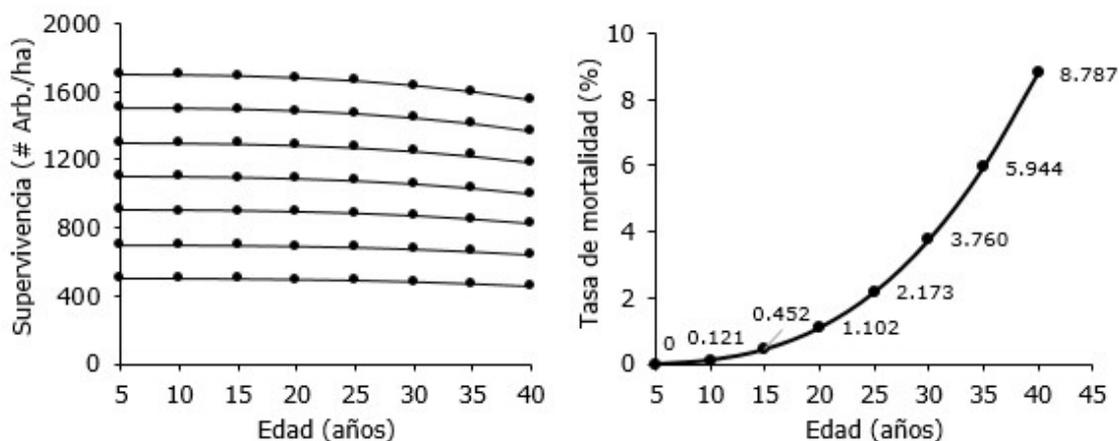


Fig. 3 Pronóstico de supervivencia y tasas de mortalidad regular en plantaciones de *Pinus caribaea* Morelet var. *caribaea* Barr. & Golf., EFI Macurije, Cuba.

Es perceptible en la figura 3, como es de esperarse, un aumento de la tasa de mortalidad regular con el envejecimiento de las plantaciones. Las tasas de mortalidad variaron entre

el 0,12 % a los 10 años a 8,78 % a los 40 años, siguiendo una forma J (o U), característica del fenómeno (mortalidad regular) estudiado Lorimer *et al.*, (2001); Maleki y Kiviste, (2016).

Proyección de la supervivencia del *Pinus caribaea* var. *caribaea* con RNAs

La utilización de las RNAs para la predicción de la supervivencia en las plantaciones de *Pinus caribaea* var. *caribaea* proporcionó resultados

satisfactorios (Tabla 3). La RNA1 de arquitectura MLP 13-10-1 presentó el mejor desempeño con proyecciones precisas y no tendenciosas (Figura 4).

Tabla 3. Resultados de los entrenamientos de las RNAs para la proyección de la supervivencia en plantaciones de *P. caribaea* var. *caribaea*, Pinar Del Rio, Cuba

RNAs	Arquitectura RNA	Función de activación		AT	RMSE (%)	R ² (%)	Sesgo
		Capa oculta	Capa de salida				
RNA_1	MLP 13-10-1	Tanh	Identity	BFGS 21	0,424	98,87	0,959
RNA_2	MLP 13-5-1	Logistic	Exponential	BFGS 9	0,889	88,93	9,831
RNA_3	MLP 13-12-1	Logistic	Tanh	BFGS 25	0,478	98,73	2,434
RNA_4	MLP 13-8-1	Tanh	Logistic	BFGS 6	0,885	89,48	10,686

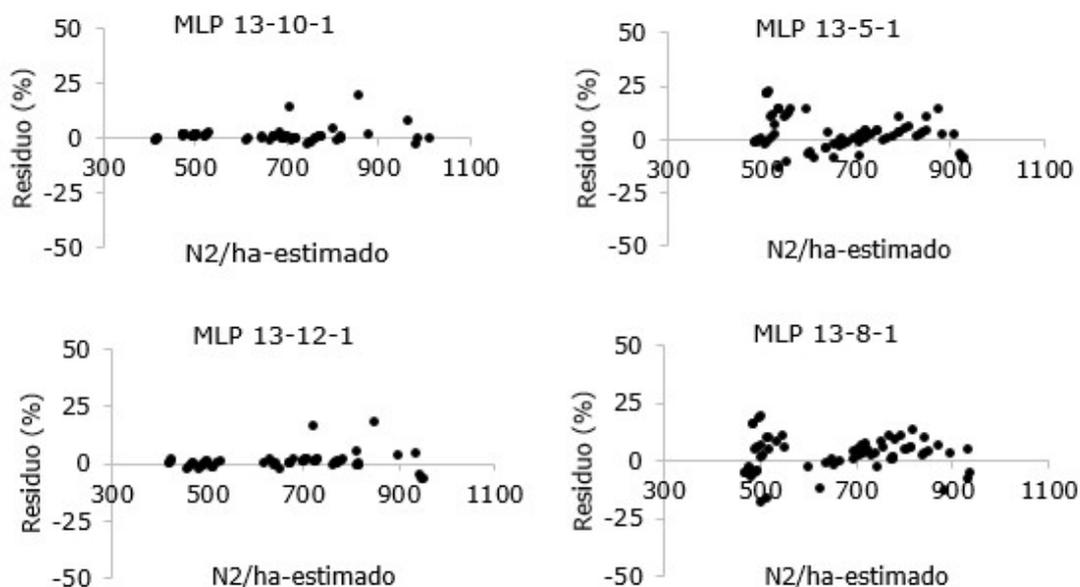


Fig. 4. Distribución de residuos de las RNAs entrenadas para la predicción de supervivencia en rodales de *Pinus caribaea* var. *caribaea*

En cuanto a la importancia de las variables en los entrenamientos, el análisis de sensibilidad indicó que la variable de mayor importancia en la proyección de la supervivencia (N_2) fue la densidad inicial (N_1) con una importancia de 0,818. Esto explica la razón por la cual es la principal variable utilizada en la predicción de la supervivencia. Las edades presentes (I_1) y futuras (I_2), también ampliamente utilizadas, presentaron importancias de 0,058 y 0,045, respectivamente. De las dos variables categóricas utilizadas, la más importante fue la UBPF con un peso de 0,051.

La variable menos contribuyente en la proyección de la supervivencia fue el índice de sitio con una importancia de 0,028. Hasta la fecha, el efecto del índice de sitio sobre la mortalidad de los árboles no está claro. La alta

variabilidad de las tasas de mortalidad observada en algunos sitios (figura 5), principalmente los sitios de bajas capacidades productivas, indica que la calidad del sitio, por sí sola, no es suficiente para explicar la mortalidad regular o emitir consideraciones conclusivas al respecto. Cualquier tendencia observada será el resultado de la combinación de los diversos factores que afectan el crecimiento y la supervivencia de los árboles Campos y Leite, (2017). Entre esos factores, están la disponibilidad de luz, agua y nutrientes que están relacionados con la calidad de sitio y son determinantes de la mortalidad regular. A esos factores, se pueden sumar los incendios, las tempestades, los vientos, las epidemias y los ataques de insectos que son causas de la mortalidad irregular, también conocida como mortalidad catastrófica de acuerdo con la clasificación de Hann (1980).

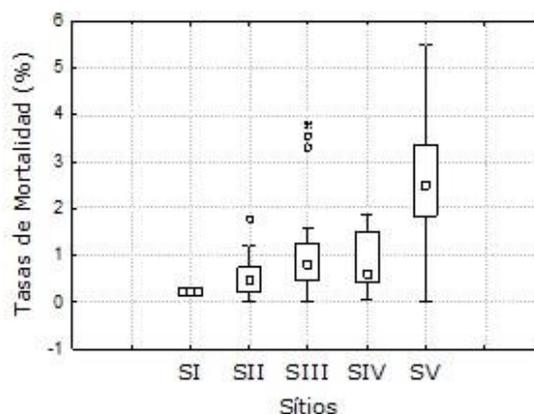


Fig. 5 Variación de los porcentajes de mortalidad regular de árboles por índice de sitio en plantaciones forestales de la EFI Macurije, Pinar del Río, Cuba

Numerosas investigaciones empíricas llegaron a resultados divergentes que se centran en tres ejes principales: (1) la calidad del sitio influye poco en la mortalidad de los árboles; (2) la mortalidad es directamente proporcional a la calidad del sitio Vanclay, (1994), es decir, que en los mejores sitios se registran mayor mortalidad como consecuencia de una mayor competencia; y (3) la mortalidad es inversamente proporcional a la calidad del sitio, es decir, mayor mortalidad en peores

sitios por poca disponibilidad de recursos.

La prueba t-pareada no fue significativa en ninguna de las comparaciones (Tabla 4), lo que indica que ambos modelos fueron eficientes en la proyección de la supervivencia. Sin embargo, los valores de los criterios de evaluación, principalmente los de RMSE (Tablas 3 y 7), indicaron una mayor precisión de la red neuronal MLP 13-10-1.

Tabla 4. Pruebas t-pareada entre las supervivencias observadas y las estimadas por el modelo de Pienaar & Shiver del año 1981 y la RNA MLP 13-10-1.

PARES	t	Sig.
OBS vs MLP 13-10-1	-0,870	0,388 ^{ns}
OBS vs Pienaar & Shiver	-0,474	0,637 ^{ns}
Pienaar & Shiver vs MLP 13-10-1	-0,679	0,500 ^{ns}

*Diferencia significativa a 99% de probabilidad por la prueba t-pareada; ns = Diferencia no significativa a 99% de probabilidad por la prueba t-pareada; OBS = Valores observados.

La ecuación resultante del ajuste del modelo de Pienaar y Shiver (1981) fue la más adecuada para la predicción de la supervivencia en las plantaciones de *Pinus caribaea* var. *caribaea* y presentó un desempeño similar al de la RNA MLP 13-10-1 seleccionada.

La flexibilidad de la estructura de las RNAs posibilitó la inclusión de variables dummies, relacionadas con la calidad de sitio y localización geográfica de los rodales (UBPFs), lo que permitió la obtención de óptimas capacidades de generalización, evidenciadas por los altos valores de R² y bajos valores de RMSE, obtenidas en las RNAs.

AGRADECIMIENTOS

Los autores del presente trabajo agradecen: a la Empresa Forestal Integral Macurije (Pinar del Río/Cuba), al Programa de Postgrado en Ciencias Forestales de la Universidad Federal

Rural de Pernambuco (PPGCF/UFRPE), al Programa PEC-PG de CAPES Brasil y al Departamento Forestal de Universidad de Pinar del Río «Hermanos Saíz Montes de Oca».

REFERENCIAS BIBLIOGRÁFICAS

- ALEIXO DA SILVA, J.A., 2015. Conceitos e princípios básicos de modelagem matemática em ciências florestais. *Anais da Academia Pernambucana de Ciência Agrônômica*, vol. 11/12, pp. 195-215.
- BIGLER, C. y BUGMANN, H., 2003. Growth-dependent tree mortality models based on tree rings. *Canadian Journal of Forest Research*, vol. 33 (2), pp. 210-221. DOI www.nrcresearchpress.com/doi/pdf/10.1139/x02-180.
- BUCHMAN, R.G., PEDERSON, S.P. y WALTERS, N.R., 1983. A tree survival model with application to species of the Great Lakes region. *Canadian Journal of Forest Research*, vol. 13, pp. 601-608.
- CAMPOS, J.C.C. y LEITE, H.G., 2017. *Mensuração florestal: perguntas e respostas*. 5a ed. S.l.: Viçosa: Editora UFV.
- CHAPMAN, D., 1961. Statistical problems in population dynamics. *Proceedings of the fourth Berkeley symposium on mathematical statistics and probability*. USA: Berkeley, CA, University of California Press, pp. 153-186.
- CLUTTER, J.L. et al., 1983. *Timber management: a quantitative approach* [en línea]. 1sted. New York: John Wiley & Sons, 1983. Disponible en: <https://www.amazon.com/Timber-Management-Quantitative-Jerome-Clutter/dp/0894647474>
- CLUTTER, J.L. y JONES, E., 1980. *Prediction of growth after thinning in old-field slash pine plantation* [en línea]. S.l.: Res. Pap. SE-217. Asheville, NC: U.S. Dept. of Agriculture, Forest Service, Southeastern Forest Experiment Station. Disponible en: <http://agris.fao.org/agris-search/search.do?recordID=US8044500>
- GLOVER, G. y HOLL, J., 1979. A basal area ratio predictor of loblolly pine plantation mortality. *Forest Science*, vol. 25 (2), pp. 275-282.
- GUAN, BIING, T. y GERTNER, G., 1991. Modeling red pine tree survival with an artificial neural network. *Forest Science*, vol. 37 (5), pp. 1429-1440.
- HAMILTON, D.A., 1974. *Event probabilities estimated by regression* [en línea]. INT-152. Utah, USA: USDA Forest Service, Intermountain Forest and Range Experiment Station, Ogden, Utah. Research Paper. Disponible en: <https://www.biodiversitylibrary.org>

- org/bibliography/68708#/summary ,
https://doi.org/10.5962/bhl.title.68708 ,
https://www.biodiversitylibrary.org/bibliography/68708#/details .
- HAMILTON, D.A., 1986. A logistic model of mortality in thinned and unthinned mixed conifer stands of Northern Idaho. *Forest Science*, vol. 32 (4), pp. 989-1000.
- HANN, D.W., 1980. *Development and evaluation of an even- and uneven-aged ponderosa pine* [en línea]. Arizona, USA: Arizona Fescue stand simulator. Ogden: Forest Service/Intermountain Forest and Range Experiment Station. Disponible en: <https://archive.org/details/developmentevalu267hann>.
- K VANCLAY, J., 1994. *Modelling forest growth and yield/ : applications to mixed tropical forests* [en línea]. S.l.: Wallingford: CAB International UK. Disponible en: https://epubs.scu.edu.au/cgi/viewcontent.cgi?article=1538&context=esm_pubs.
- L KING, S., BENNETT, K.P. y LIST, S., 2000. Modelling non-catastrophic individual tree mortality using logistic regression, neural networks, and support vector methods. *Computers and Electronics in Agriculture*, vol. 27, pp. 401-406.
- LEE, Y., 1971. Predicting mortality for even-aged stands of lodgepole pine. *Forestry Chronicle*, vol. 47(1), pp. 29-32.
- LORIMER, C.G., DAHIR, S., y NORDHEIM, E., 2001. Tree mortality and longevity in mature and old-growth hemlockhardwood forests. *Journal of Ecology*, vol. 89, pp. 960-971. DOI <http://www.nrcresearchpress.com/doi/abs/10.1139/X10-14>.
- MALEKI, K. y KIVISTE, A., 2016. Individual tree mortality of silver birch (*Betula pendula* Roth) in Estonia. *iForest*, vol. 9, pp. 643-651.
- PIENAAR, L.V. y SHIVER, B.D., 1981. Survival functions for site prepared slash pine plantations in the flat woods of Georgia Northern Florida. *Southern Jour. Forestry*, vol. 5 (2), pp. 59-62.
- RICHARDS, F.J., 1959. A flexible growth function for empirical use. *Journal of Experimental Botany*, vol. 10, pp. 290-300.
- SANQUETTA, C.R., 1990. *Predição da sobrevivência em reflorestamentos de Pinus elliottii Engelm* [en línea]. Tesis de Maestría para la obtención del título de Máster en Ingeniería Forestal. Brasil, Curitiba: Universidade Federal do Paraná. Disponible en: <https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=ad&id=305301&biblioteca=vazio&busca=autoria:%22SANQUETTA,%20%20C.%20R.%22&qFacets=autoria:%22SANQUETTA,%20%20C.%20R.%22&sort=&pagina=1>.
- SILVA, J.A.A. DA, 1986. *Dynamics of stand structure in fertilized slash pine plantations* [en línea]. Georgia Athens, USA: University of Georgia. Disponible en: https://books.google.com/cu/books/about/Dynamics_of_Stand_Structure_in_Fertilize.html?id=6Y5TNwaACAAJ&redir_esc=y.
- VANCLAY, J.K., 1991. Mortality functions for north Queensland rain forests. *Journal of Tropical*

Forest Science, vol. 4 (1), pp. 15-36.