



7º CONGRESO FORESTAL ESPAÑOL

**Gestión del monte: servicios
ambientales y bioeconomía**

26 - 30 junio 2017 | Plasencia
Cáceres, Extremadura

7CFE01-568

Edita: Sociedad Española de Ciencias Forestales
Plasencia. Cáceres, Extremadura. 26-30 junio 2017
ISBN 978-84-941695-2-6

© Sociedad Española de Ciencias Forestales

Obtención del módulo de elasticidad estático de la madera de *Pinus radiata* D. Don. mediante la comparación de técnicas de regresión y una red neuronal artificial

GARCIA IRUELA, A.¹, GARCIA FERNANDEZ, F.¹, ESTEBAN, L.G.¹, DE PALACIOS, P.¹, SIMON, C.¹ y ARRIAGA, F.²

¹ Cátedra de Tecnología de la Madera, Departamento de Sistemas y Recursos Naturales, Escuela Técnica Superior de Ingeniería de Montes, Forestal y del Medio Natural, Universidad Politécnica de Madrid, Ciudad Universitaria, 28040 Madrid, España.

² Cátedra de Cálculo de Estructuras, Departamento de Ingeniería y Gestión Forestal y Ambiental, Escuela Técnica Superior de Ingeniería de Montes, Forestal y del Medio Natural, Universidad Politécnica de Madrid, Ciudad Universitaria, 28040 Madrid, España.

Resumen

La utilización de ensayos no destructivos combinada con modelizaciones predictivas permite obtener propiedades mecánicas de un material sin afectarle. Se ha comparado el método de regresión tradicional frente al de una red neuronal artificial para obtener el $MOE_{estático}$ de la madera de *Pinus radiata* a través del $MOE_{dinámico}$ determinado por ultrasonidos, en el primer caso, y a partir de la velocidad de propagación de la onda de ultrasonidos en el segundo.

Para ello se han utilizado 198 probetas de 40x100x2100 mm obtenidas de 15 árboles procedentes de un monte repoblado del municipio de Zeanuri - Vizcaya (España).

Las variables de entrada en la red neuronal artificial han sido las dimensiones de las piezas (altura y anchura), la velocidad de propagación de ultrasonidos en testas y cantos, la densidad y el contenido de humedad y la variable de salida el $MOE_{estático}$.

Mientras que el modelo de regresión es capaz de explicar en el mejor de los casos el 70% de la variabilidad de las muestras, la red neuronal artificial es capaz de hacerlo en el 80%, lo cual pone de manifiesto que este tipo de herramienta mejora la estimación del $MOE_{estático}$ cuando este se obtiene haciendo uso de la técnica de ultrasonidos.

Palabras clave

Propiedades mecánicas, ultrasonidos, modelado computacional.

1. Introducción

En la industria de la madera y derivados de ella, las técnicas de ensayos no destructivos han ido aumentando en los últimos años ya que permiten la obtención de las propiedades mecánicas de un material sin afectar de forma permanente al mismo (ROSS et al., 1998).

En la madera, el módulo de elasticidad (MOE) se relaciona con la mayoría de las propiedades mecánicas el cual puede obtenerse mediante ensayos estáticos o métodos no destructivos (GUNTEKIN et al., 2014). Los resultados obtenidos por ambos métodos, el módulo de elasticidad estático ($MOE_{estático}$) y dinámico ($MOE_{dinámico}$) respectivamente, guardan una estrecha relación, con coeficientes de determinación superiores a 0.8 (GUNTEKIN et al., 2014).

Sin embargo, estas correlaciones no siempre son tan altas y en algunos casos los coeficientes de determinación sólo superan ligeramente el 0.6 o ni siquiera llegan al 0.5 (ARRIAGA et al., 2006; ESTEBAN et al., 2009).

Debido a esto, las redes neuronales artificiales se han convertido en una alternativa de modelización estadística, mejorando casi siempre las correlaciones obtenidas mediante los métodos clásicos de regresión (KEWALRAMANI & GUPTA, 2006; TANG et al., 2007).

2. Objetivos

El objetivo de este estudio ha sido comparar el método de regresión tradicional frente al diseño de una red neuronal artificial del tipo perceptrón multicapa para obtener el $MOE_{estático}$ de la madera de *Pinus radiata* D. Don. a partir del $MOE_{dinámico}$ obtenido por técnica de ultrasonidos en el primer caso y a partir de la velocidad de propagación de la onda de ultrasonidos en el segundo.

3. Metodología

A partir de 15 árboles representativos de un monte repoblado de 43 años, situado en el municipio de Zeanuri en la provincia de Vizcaya (España), se obtuvieron 198 probetas de madera de *Pinus radiata* de 40x100 mm de sección y longitud 2100.

Las trozas se despiezaron sobre un costero en espesores de 45 mm. Los tablones se secaron al aire y posteriormente se acondicionaron en cámara a una humedad relativa del $65\pm 5\%$ y a una temperatura de $20\pm 2^\circ\text{C}$, finalmente se regruesaron a 40 mm.

La norma UNE 56544 (AENOR, 2011) se utilizó para la clasificación visual de las probetas, la cual agrupa la madera estructural de anchura igual o inferior a 70 mm en dos clases (ME-1, ME-2) en función de defectos como nudos, fendas, acebolladuras, bolsas de resina, etc.

La velocidad de propagación de la onda de ultrasonidos se ha medido mediante un equipo CBS-CBT Ingenierie Technologie Construction Boiss mod. SYLVATEST-TRIO rango 0.80-20 m y frecuencia 22 kHz (Figura 1).

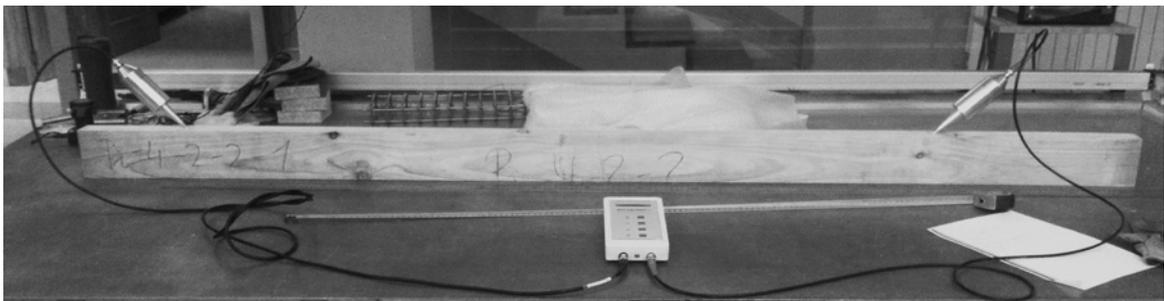


Figura 1. Equipo de medida de la velocidad de propagación de la onda de ultrasonidos para $MOE_{dinámico}$,

Mediante las fórmulas desarrolladas por diversos autores (SANDOZ, 1989; LOURENÇO et al., 2007; ARRIAGA et al., 2006) que relacionan el MOE con la densidad y el cuadrado de la velocidad de propagación, se obtuvo el $MOE_{dinámico}$.

$$MOE_{dynamic} = a_1 \cdot \rho \cdot v^2 + a_2$$

$MOE_{dinámico}$: módulo de elasticidad dinámico

ρ : densidad

v : velocidad de propagación

a_1 y a_2 : constantes

(1)

Se ha utilizado la velocidad de propagación obtenida en las testas y en los cantos así como las medias de ellas.

$$v = v_{testas} \tag{2}$$

$$v = v_{canto1} \tag{3}$$

$$v = v_{canto2} \tag{4}$$

$$v = \frac{v_{testas} + v_{canto1} + v_{canto2}}{3} \tag{5}$$

$$v = \sqrt{v_{testas}^2 + v_{canto1}^2 + v_{canto2}^2} \tag{6}$$

Se calculó el $MOE_{estático}$ de acuerdo a la norma de ensayo UNE-EN 408 (AENOR, 2012) (Figura 2), utilizando una máquina universal de ensayos MICROTTEST con célula de carga de 40 kN y clase 1. Con un LVDT externo de 0.001 mm de división de escala se obtuvo la medida de la deformación durante el ensayo.

De cada probeta se determinó la densidad según la norma UNE-EN 408 (AENOR, 2012) y el contenido de humedad según la norma UNE-EN 13183-1 (AENOR, 2002) una vez realizado el ensayo, obteniendo para ello una rebanada libre de nudos y bolsas de resina de la sección completa de la pieza más próxima a la zona de rotura.

Para la determinación de las propiedades físicas se utilizaron una estufa MEMMERT D06836 de rango 0-250°C y 0.1°C de división de escala, una balanza COBOS CB-600 de rango 0-600 g y 0.01 g de división de escala, y un calibre digital MITUTOYO Digimatic de 0-300 mm de rango y 0.01 mm de división de escala.

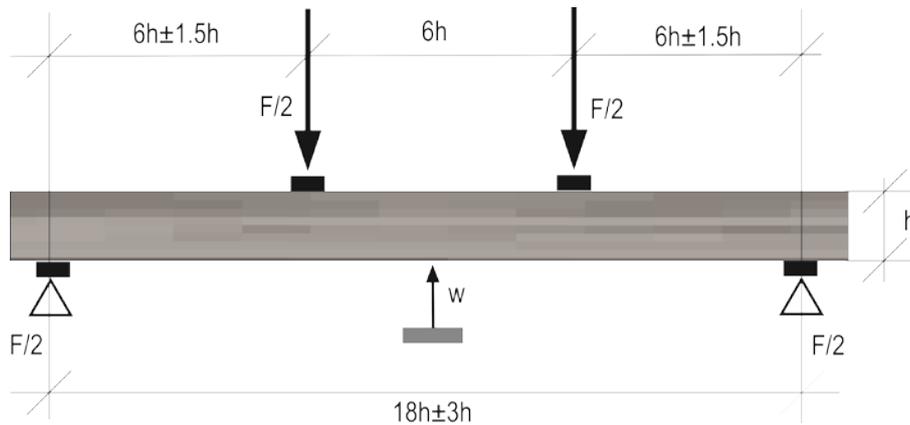


Figura 2. Esquema del ensayo UNE-EN 408 para la obtención del módulo de elasticidad. F: Carga aplicada, h: altura de la probeta, w: deformación

Para el diseño de la red neuronal se ha optado por un perceptrón multicapa y como variables de entrada, la densidad, la velocidad de propagación de la onda de ultrasonidos medida en las testas y los cantos, las dimensiones de la sección transversal y el contenido de humedad en el momento del ensayo. Como variable de salida se ha considerado el $MOE_{estático}$ (Fig. 3).

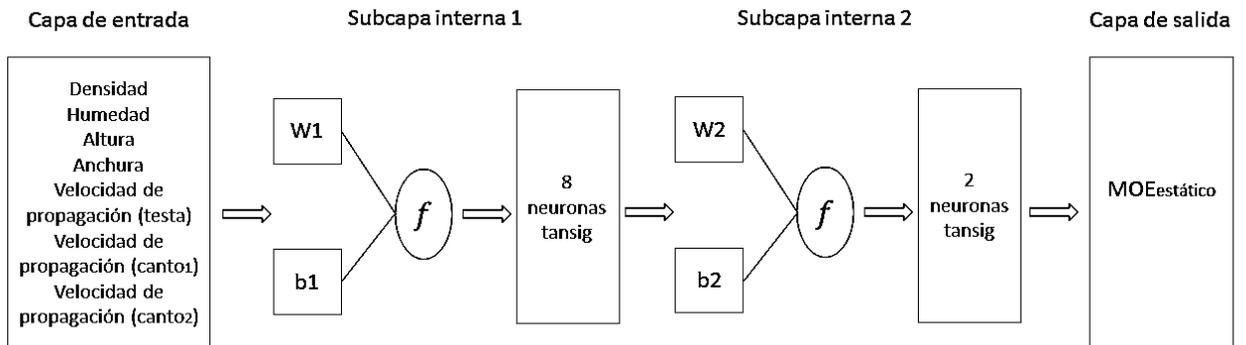


Figura 3. Esquema de la red neuronal utilizada.

Como función de transferencia se ha utilizado la tangente hiperbólica sigmoidea, matemáticamente equivalente a la tangente hiperbólica pero que mejora el funcionamiento de la red (DEMUTH et al., 2002). Como algoritmo de entrenamiento se ha utilizado la retropropagación resiliente, que mejora notablemente los resultados para el caso de funciones de transferencia sigmoidea (DEMUTH et al., 2002).

El conjunto inicial de datos se ha dividido en tres subconjuntos de forma aleatoria, los conjuntos de entrenamiento, validación y comprobación con unas proporciones de 60-20-20 respectivamente. Durante el proceso de entrenamiento, se ha evaluado de forma continua el error en los conjuntos de entrenamiento y validación. El overfitting se manifiesta en el momento en el que el error en el conjunto de validación comienza a aumentar mientras que en el conjunto de entrenamiento sigue descendiendo. En ese punto se considera que la red ha completado su proceso de aprendizaje. El tercer conjunto se utiliza para obtener el grado de generalización de la red, evitando cualquier tipo de sesgo introducido por los conjuntos de entrenamiento y validación (BISHOP, 1995).

Para comparar los resultados obtenidos mediante la red neuronal artificial y los ajustes estadísticos se ha utilizado el coeficiente de determinación (R^2).

4. Resultados

Los porcentajes obtenidos en la clasificación visual se reflejan en la (Tabla 1) y los valores de ensayo de la anchura y altura de las piezas, velocidad de propagación de la onda de ultrasonidos en testa y cantos, contenido de humedad, densidad y $MOE_{estático}$ en la (Tabla 2).

Tabla 1. Clasificación visual

Clase	nº de piezas	Porcentaje (%)
ME-1	25	12.63
ME-2	67	33.84
Rechazo	106	53.54

Tabla 2. Resultados de ensayo

Variable	Media	Desviación típica	CV (%)	Mínimo	Máximo
Anchura (mm)	39.3	1.7	4.4	33.9	43.7
Altura (mm)	99.8	0.6	0.6	95.8	100.8
Velocidad en testas (m/s)	5368.7	382.7	7.4	3997.9	6045.0
Velocidad en canto ₁ (m/s)	5151.6	611.3	12.0	1071.7	6117.4
Velocidad en canto ₂ (m/s)	5150.4	552.2	11.0	1634.0	6104.4
Contenido de humedad (%)	10.5	0.6	6.1	9.1	12.1
Densidad (kg/m ³)	489.0	62.7	12.8	353.0	808.2
$MOE_{estático}$ (N/mm ²)	9011.1	2209.9	25.2	2293.9	13912.6

Como paso previo al desarrollo de los modelos de regresión y la red neuronal artificial se procedió a un análisis de componentes principales tomando como nivel crítico una contribución a la variabilidad de la muestra de un 2%, alcanzándose en todas las variables implicadas en el proceso una contribución superior.

Los coeficientes de las distintas ecuaciones de regresión para la determinación del $MOE_{estático}$ a partir del $MOE_{dinámico}$, tomando como velocidades de propagación las ecuaciones 2-6, se muestran en la (Tabla 3). El p-valor inferior a 0.05 indica que existe una relación estadísticamente significativa entre el módulo de elasticidad y las variables utilizadas con un nivel de confianza del 95%.

Tabla 3. Datos estadísticos del ajuste de la regresión

Ecuación	Parámetros (95% intervalo de confianza)	R^2	R	F	p-valor
(2)	$a_1 = 5.86 \cdot 10^{-4}$ ($5.24 \cdot 10^{-4}$; $6.48 \cdot 10^{-4}$) $a_2 = 661.68$ (-246.77; 1570.10)	0.64	0.80	343.16	<0.01
(3)	$a_1 = 5.04 \cdot 10^{-4}$ ($4.46 \cdot 10^{-4}$; $5.62 \cdot 10^{-4}$) $a_2 = 2334.90$ (1543.23; 3126.64)	0.60	0.78	294.75	<0.01
(4)	$a_1 = 5.07 \cdot 10^{-4}$ ($4.50 \cdot 10^{-4}$; $5.65 \cdot 10^{-4}$)	0.61	0.78	307.44	<0.01

	$a_2 = 2296.11$ (1543.20; 3075.92)				
(5)	$a_1 = 6.58 \cdot 10^{-5}$ ($5.96 \cdot 10^{-5}$; $7.19 \cdot 10^{-4}$) $a_2 = 998.88$ (233.07; 1764.73)	0.70	0.83	448.20	<0.01
(6)	$a_1 = 2.05 \cdot 10^{-4}$ ($1.86 \cdot 10^{-4}$; $2.24 \cdot 10^{-4}$) $a_2 = 645.41$ (-135.15; 1425.96)	0.70	0.84	465.79	<0.01

El mejor de los coeficientes de determinación obtenidos es de 0.70 por lo que en el mejor de los casos los modelos estadísticos propuestos son capaces de explicar el 70% de la variabilidad de las muestras.

La red óptima desarrollada es un perceptrón multicapa con 8 y 2 neuronas en las capas ocultas. Esto implica que la red está matemáticamente definida ya que se disponen de 122 datos en el conjunto de entrenamiento frente a los 83 necesarios (SHA, 2007).

En la (Tabla 4) se muestran los resultados del proceso de entrenamiento de la red.

Tabla 4. Resultados obtenidos por la red neuronal artificial desarrollada

Conjunto	Modelo lineal de regresión	R ²	R
Entrenamiento	$y = 0.884.6x + 1036$	0.90	0.95
Validación	$y = 0.893.8x + 676.8$	0.81	0.90
Comprobación	$y = 0.891.4x + 856$	0.80	0.90
Total	$y = 0.887.7x + 933$	0.86	0.93

El coeficiente de determinación obtenido para el conjunto de comprobación es 0.80 lo cual indica que la red obtenida es capaz de explicar el 80% de la variabilidad de las muestras.

La (Figura 4) muestra el gráfico de regresión para el mejor ajuste, mientras que la (Figura 5) muestra las correlaciones obtenidas por la red en el conjunto de comprobación.

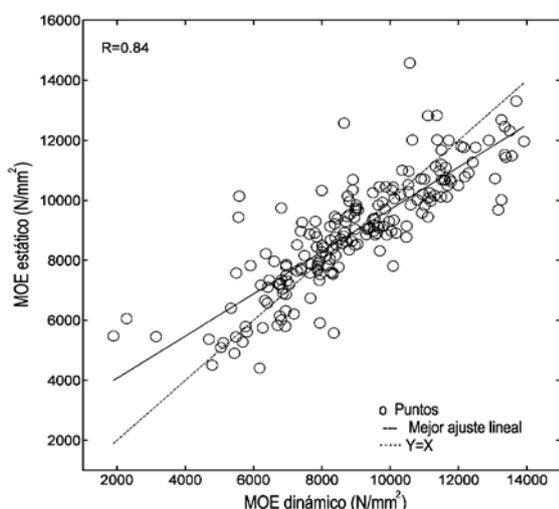


Figura 4. Relación existente entre el $MOE_{estático}$ y $MOE_{dinámico}$ en la ecuación 6.

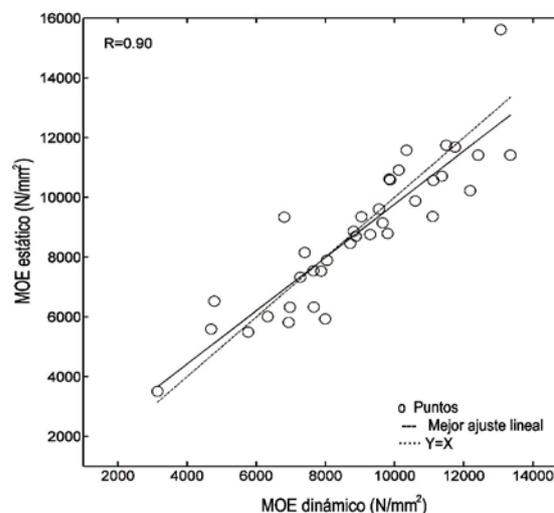


Figura 5. Correlación en el conjunto de comprobación.

5. Discusión

La diferencia en las velocidades medias entre las testas (5368.7 m/s) y los cantos (5151 m/s) obedece al distinto comportamiento de la madera frente al sonido en la dirección longitudinal y transversal. La proporción de 0.96 entre ambas es muy similar al obtenido por otros autores que estudiaron la influencia del posicionamiento del sensor (ARRIAGA et al., 2015).

En este estudio, las velocidades de propagación son similares a las recogidas por BRAVO (1996) de 5249 m/s en sus estudios de *Pinus radiata* y ligeramente superiores a las de NIEMZ et al. (1994), de 5036 m/s para esta misma especie. Estas ligeras diferencias pueden ser debidas a la variabilidad de la especie como al uso de diferentes frecuencias (BUCUR, 2006).

De igual manera, el MOE_{estático} (9011 N/mm²), se encuentra en los intervalos de otros estudios sobre la misma especie, HERMOSO et al., (2007) 8230-10796 N/mm², MONTÓN et al. (2011) 7871-10102 N/mm², y es similar a los valores obtenidos por ARRIAGA et al. (2012) 9009 N/mm² y ARRIAGA et al. (2014) 8952 N/mm².

La alta variabilidad que se ha encontrado en con un El coeficiente de variación es de 25.2% en el MOE_{estático} y presenta una alta variabilidad similar a la hallada por ARRIAGA et al. (2012; 2014) en sus estudios del cálculo del MOE de la madera estructural mediante el método de vibraciones longitudinales y transversales, con valores de coeficientes de variación del 20.2% y el 23.7% respectivamente, para el *Pinus radiata*. Otros autores también obtuvieron coeficientes de variación elevados: NIEMZ et al. (1994) 28.9% y MONTÓN et al. (2011) entre el 20% y el 24%.

Esa alta variabilidad se debe al elevado número de defectos en las piezas estudiadas (LINDSTRÖM et al., 2009), además, el gran porcentaje de rechazos (53.54%) (Tabla 1) es consecuencia del elevado número de defectos encontrados. Estudios sobre la misma especie, (MONTÓN et al., 2011) aportan porcentajes de rechazo similares al de este estudio, con valores del 47% para piezas de ancho superior a 70 mm y del 55% para piezas de ancho igual o inferior a 70 mm. Por el contrario, otros autores han puesto de manifiesto porcentajes de rechazo menores como los aportados por HERMOSO et al. (2007), con un 37%, o de tan sólo el 17% por ARRIAGA et al. (2014). Por el contrario, otros autores Estas variaciones en el porcentaje de rechazos durante la clasificación visual pueden ser atribuibles a la calidad de la estación, la procedencia de la planta y la selvicultura realizada, entre otros factores.

Trabajos de aplicación de ultrasonido a la madera de esta especie han descrito coeficientes de correlación con valores entre 0.75 y 0.87 (BARADIT et al., 1998) y ARRIAGA et al. (2012, 2014) 0.74 y 0.87 respectivamente. Otros autores, sin embargo, obtuvieron coeficientes de correlación inferiores como el de NIEMZ et al. (1994) siendo 0.66.

Que los resultados obtenidos en la modelización mediante la red neuronal artificial sean superiores a los obtenidos mediante los modelos clásicos de regresión concuerda con los resultados de otros autores (KEWALRAMANI & GUPTA 2006; TANG et al., 2007).

No obstante, que los coeficientes de determinación obtenidos para el conjunto de comprobación (0.80) por esta red neuronal artificial sean menores que los conseguidos por regresión por otros autores (TELES et al., 2011), puede explicarse por el elevado número de rechazos, fruto del alto número de defectos de las piezas, es decir, probablemente estos autores utilizaron piezas con menor número de defectos en ellas. De hecho, SCHEFFLER et al. (2002) o LINDSTRÖM (2009) describieron la enorme influencia que ejercen los defectos presentes en la madera en la velocidad de propagación y, por tanto en el MOE. Así mismo, CHUI (1991) señaló que las variaciones en el MOE debido a la presencia de nudos pueden llegar al 25%.

6. Conclusiones

- Los resultados obtenidos ponen de manifiesto que las redes neuronales artificiales son apropiadas para modelizar las relaciones entre densidad, contenido de humedad, dimensiones de la pieza y velocidad de propagación de la onda de ultrasonidos de la madera de *Pinus radiata* y el MOE, mejorando los coeficientes de correlación obtenidos con modelos de regresión tradicionales.

- El uso de técnicas no destructivas junto al diseño de redes neuronales artificiales se convierte en una combinación de procedimientos que puede resultar de especial importancia en el estudio de estructuras de madera en edificios históricos y en su consiguiente restauración.

7. Bibliografía

ARRIAGA, F.; IÑIGUEZ, G.; ESTEBAN, M.; FERNÁNDEZ-GOLFIN, J.I.; 2006. Structural Tali timber (*Erythrophleum ivorense* A. Chev., *Erythrophleum suaveolens* Brenan.): Assessment of strength and stiffness properties using visual and ultrasonic methods. *Holz Als Roh- und Werkst* 64(5) 357 – 362.

ARRIAGA, F.; IÑIGUEZ-GONZÁLEZ, G.; ESTEBAN, M.; DIVOS, F.; 2012. Vibration method for grading of large cross-section coniferous timber species. *Holzforschung* 66(3) 381 – 387.

ARRIAGA, F.; MONTÓN, J.; SEGUES, E.; IÑIGUEZ-GONZALEZ, G.; 2014. Determination of the mechanical properties of radiata pine timber by means of longitudinal and transverse vibration methods. *Holzforschung* 68(3) 299 – 305.

ARRIAGA, F.; LLANA, D.F.; MARTÍNEZ, R.; ESTEBAN, M.; IÑIGUEZ-GONZÁLEZ, G.; 2015. The influence of sensor placement on in-situ ultrasound wave velocity measurement. In: Proceedings of the 19th International Symposium on Nondestructive Testing of Wood. Rio de Janeiro, September.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR); 2011. UNE 56544. Clasificación visual de la madera aserrada para uso estructural. Madera de coníferas. AENOR. Madrid

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR); 2002. UNE-EN 13183-1. Contenido de humedad de una pieza de Madera aserrada. Parte 1: Determinación por el método de secado en estufa. AENOR. Madrid

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR); 2012. UNE-EN 408+A1. Estructuras de Madera. Madera aserrada y madera laminada encolada para su uso estructural. Determinación de algunas propiedades físicas y mecánicas. AENOR. Madrid

BARADIT, E.; ROZAS, C.; VARGAS, G.; 1998. Ultrasound application for *Pinus radiata* D. Don evaluation. *Maderas-Cienc Tecnol* 1(1) 27 – 33.

BISHOP, C.M.; 1995. Neural networks for pattern recognition. Oxford University Press. 504 páginas. Oxford

BRAVO, I.; 1996. Evaluación preliminar de la anisotropía y determinación del módulo de elasticidad de la madera de *Pinus radiata* D. Don por ultrasonido. Memoria Ingeniero Civil en Industrias Forestales, Departamento de Ingeniería en Maderas, Universidad del Bío-Bío. 70 páginas. Concepción, Chile

BUCUR, V.; 2006. Acoustics of Wood. Springer-Velag. 345 páginas. Berlín

CHUI, Y.J.; 1991. Simultaneous evaluation of bending and shear moduli of wood and the influence of knots on these parameters. *Wood Sci Technol* 25(2) 125 – 134.

DEMUTH, H.; BEALE, M.; HAGAN, M.; 2002. Neural Network Toolbox User's Guide, Version 4. Natick: The MathWorks Inc. 846 páginas. Natick, MA.

ESTEBAN, L.G.; FERNANDEZ, F.G.; DE PALACIOS, P.; 2009. MOE prediction in *Abies pinsapo* Boiss. timber: Application of an artificial neural network using non-destructive testing. *Comput Struct* 87 1360 – 1365.

GUNTEKIN, E.; OZKAN, S.; YILMAZ, T.; 2014. Prediction of bending properties for beech lumber using stress wave method. *Maderas-Cienc Tecnol* 16(1) 93 – 98.

HERMOSO, E.; CARBALLO, J.; FERNÁNDEZ-GOLFÍN, J.I.; 2007. Structural characterization of *Pinus radiata* D. Don timber from Pais Vasco (Spain) according to standard modifications. *Maderas-Cienc Tecnol* 9(3) 223 – 232.

KEWALRAMANI, M.; GUPTA, R.; 2006. Concrete compressive strength prediction using ultrasonic pulse velocity through artificial neural networks. *Autom Constr* 15(3) 374 – 379.

LINDSTRÖM, H.; REALE, M.; GREKIN, M.; 2009. Using non-destructive testing to assess modulus of elasticity of *Pinus sylvestris* trees. *Scand J Forest Res* 24 247 – 257.

LOURENÇO, P.B.; FEIO, A.O.; MACHADO, J.S.; 2007. Chestnut wood in compression perpendicular to the grain: Non-destructive correlations for test results in new and old wood. *Constr Build Mater* 21(8) 1617 – 1627.

MONTÓN, J.; ARRIAGA, F.; AVELLANEDA, J.; IÑIGUEZ-GONZÁLEZ, G.; FARRÁS, J.; PLENSA, R.; 2011. Clasificación visual de la madera de pino radiata procedente de Cataluña. In: 1º Congreso Ibero – Latinoamericano da Madeira na Construção, CIMAD 11. Coimbra.

NIEMZ, P.; AGUILERA, A.; ROLLERI, A.; 1994. Ultrasound propagation on some wood species in Chile and its relation with physical properties. *Bosque* 15(2) 49 – 54. (In Spanish).

ROSS, R.J.; BRASHAW, B.K.; PELLERIN, R.F.; 1998. Nondestructive evaluation of wood. *For Prod J* 48(1) 14 – 19.

SANDOZ, J.L.; 1989. Grading of construction timber by ultrasound. *Wood Sci Technol* 23(1) 95 – 108.

SCHEFFLER, M.; NIEMZ, P.; HARDTKE, H.J.; 2002. Numerical simulation of sound propagation in wood in presence of defects. *Holz Als Roh- und Werkst* 60(6) 397 – 404. (In German).

SHA, W.; 2007. Comment on the issues of statistical modelling with particular reference to the use of artificial neural networks. *Appl. Catal. A-Gen.* 324 87 – 89.

TANG, C.W.; LIN, Y.C.; KUO, S.F.; 2007. Investigation on correlation between pulse velocity and compressive strength of concrete using ANNs. *Comput Concr* 4(6) 477 – 497.

TELES, R.F.; DEL MENEZZI, C.S.; DE SOUZA, F.; DE SOUZA, M.R.; 2011. Nondestructive evaluation of a tropical hardwood: Interrelationship between methods and physical-acoustical variables. *Ciência da Madeira* 2(1) 01 – 14.