



7º CONGRESO FORESTAL ESPAÑOL

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

26 - 30 junio 2017 | Plasencia
Cáceres, Extremadura

7CFE01-554

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

© Sociedad Española de Ciencias Forestales

Predicción de la resistencia a tracción del tablero de partículas a partir de los parámetros de producción mediante el uso de redes neuronales artificiales

García Fernández, F.¹, de Palacios, P.¹, García-Iruela, A.¹, García Esteban, L.¹, González Rodrigo, B.².

¹Dpto. de Sistemas y Recursos Naturales. ETS de Ingeniería de Montes, Forestal y del Medio Natural. Universidad Politécnica de Madrid. Ciudad Universitaria S/N. 28040 Madrid.

²Dpto. Ingeniería Civil: Construcción, Infraestructuras y Transportes ETS de Ingeniería Civil. Universidad Politécnica de Madrid. Ciudad Universitaria S/N. 28040 Madrid.

Resumen

Una de las propiedades más importantes dentro de control de calidad del tablero de partículas es la resistencia a tracción ya que es un indicador del nivel de cohesión interna del tablero. Sin embargo, la necesidad del acondicionamiento previo hace que este ensayo carezca de la inmediatez necesaria para su aplicación en tiempo real. Para solventar este problema se ha modelizado la resistencia a tracción del tablero de partículas P2 a partir de los parámetros de producción mediante el uso de una red neuronal artificial.

Para ello se han utilizado 300 tableros de los cuáles se han tomado datos en la línea de producción de la temperatura de las partículas y de la resina, contenido de humedad de la manta, porcentajes de adhesivo, porcentaje y tipo de aditivos, velocidad de la manta y temperatura de las prensas. Estos tableros fueron despiezados en fábrica para posteriormente acondicionarlos en el laboratorio y realizar los ensayos de resistencia a tracción, humedad y densidad.

La red desarrollada ha obtenido en el conjunto de comprobación un coeficiente de correlación (R) de 0,87, que indica una suficiente fiabilidad para su aplicación en el control diario de producción.

Palabras clave

Inteligencia artificial, modelización, cohesión interna, propiedades mecánicas, RNA.

1. Introducción

El tablero de partículas es un tablero derivado de la madera a base de partículas aglutinadas con diferentes tipos de cola dependiendo de su destino final. Su consumo ha experimentado un ligero crecimiento en los últimos años debido especialmente a la demanda del sector de mobiliario tanto doméstico como de oficina. De acuerdo a los últimos datos de la FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (2010) la producción mundial se estima en unos 100 millones de metros cúbicos, generando un mercado de unos $15.1 \cdot 10^3$ millones de dólares.

Una de las propiedades más importantes dentro de su control de calidad en fábrica es la cohesión interna del tablero medida a partir del ensayo de tracción perpendicular a las caras UNE-EN 319 (AENOR, 1994a). Sin embargo, la necesidad de un acondicionamiento previo, para poder aplicar las especificaciones recogidas en la norma UNE EN 312 (AENOR 2010) hace que este ensayo carezca de la inmediatez necesaria para su aplicación en tiempo real al control de la línea de producción.

Este retraso en la obtención de los resultados del ensayo es un problema que afecta de forma importante a la industria manufacturera en general (MORRIS et al. 1994) y a la industria de tableros derivados de la madera en particular (COOK et al. 2000). Por esta razón es importante poder disponer de una serie de herramientas de modelización que permitan obtener las propiedades físicas y

mecánicas del tablero a partir de los parámetros de fabricación tomados directamente de la línea de producción. En este aspecto, el uso de redes neuronales artificiales se ha extendido durante los últimos años en numerosos campos de la ciencia y la tecnología, gracias a su gran capacidad de modelización de procesos y a la fiabilidad de sus resultados.

Las redes neuronales artificiales son una disciplina de la inteligencia artificial enfocada, entre muchas de sus aplicaciones, a la modelización de datos. El carácter de aproximadores universales de algunas de ellas, como el perceptrón multicapa (HORNIK et al., 1989) (Figura 1), y su robustez frente al valores anómalos les confiere una gran capacidad para modelizar todo tipo de relaciones entre variables con un alto grado de fiabilidad aunque detrimento del conocimiento de las posibles relaciones entre las variables implicadas (De VEAUX et al., 1998).

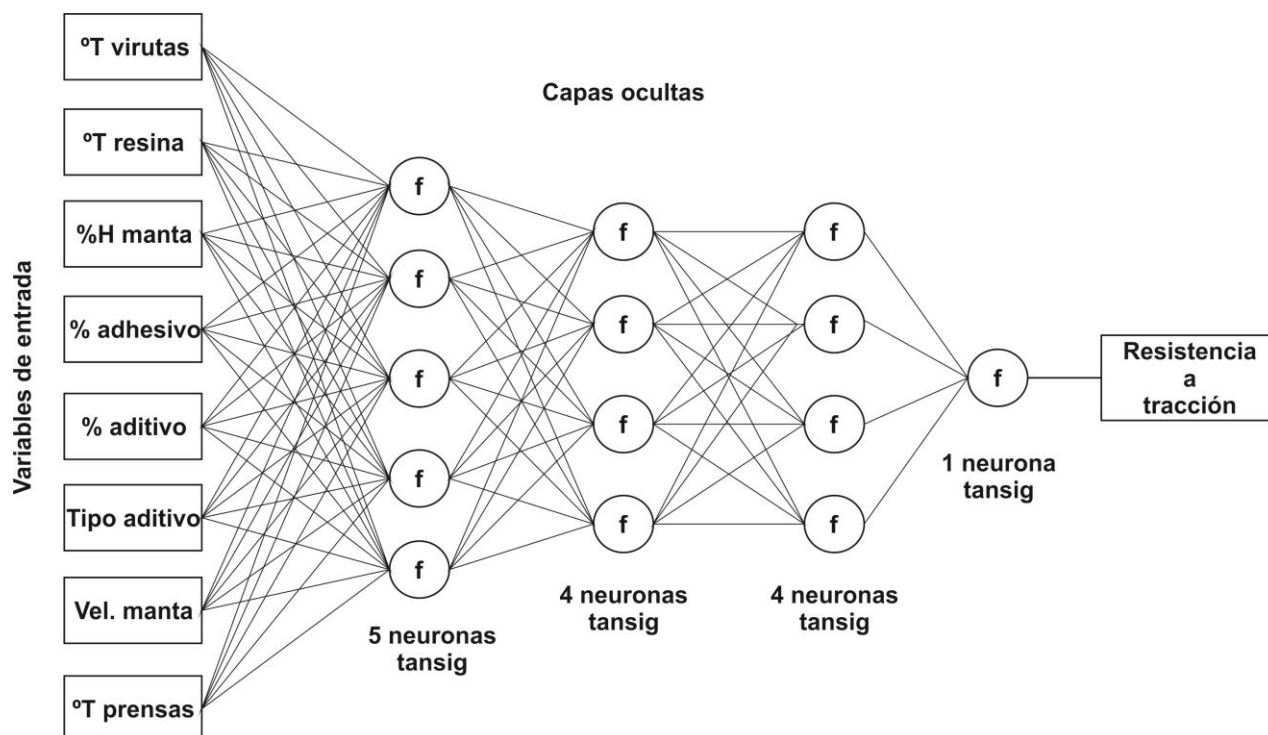


Figura 1. Esquema de la red neuronal

Estos modelos matemáticos han sido aplicados con éxito a la obtención de propiedades mecánicas de la madera, o productos derivados de ella, a partir de otras propiedades más sencillas de medir (GARCÍA FERNÁNDEZ et al., 2012) o de parámetros de fabricación (COOK & CHIU, 1997; OZSAHIN, 2012; DEMIRKIR et al., 2013; BARDAK et al., 2016).

2. Objetivos

El objetivo de este estudio ha sido el obtener un modelo predictivo de la resistencia a tracción del tablero de partículas acondicionado con la suficiente fiabilidad para su utilización en el control de calidad diario. Para ello, se ha desarrollado una red neuronal artificial a partir de los parámetros de fabricación.

3. Metodología

3.1. Tablero de partículas

De todos los tipos de tableros de partículas, el tablero P2, según UNE-EN 312 (AENOR, 2010) es un tablero destinado principalmente a la fabricación de mobiliario de interior el cuál se fabrica a partir de partículas de madera encoladas con colas de urea formaldehído.

En este estudio, se han utilizado 300 tableros de partículas P2 en los cuáles se ha medido la resistencia a tracción de acuerdo a la norma UNE EN 319 (AENOR, 1994a) (Figura 2), la humedad de acuerdo a la norma UNE EN 322 (AENOR, 1994b) y la densidad de acuerdo a la norma UNE EN 323 (AENOR, 1994c). La resistencia a tracción se ha relacionado con los parámetros de producción de temperatura de las virutas y de la resina, contenido de humedad de la manta, porcentajes de adhesivo, porcentaje y tipo de aditivos, velocidad de la manta y temperatura de las prensas.




Figura. 2. Ensayo de tracción perpendicular a las caras

Todas las probetas se han obtenido de acuerdo a la norma UNE-EN 326-1 (AENOR 1995) y han sido acondicionadas en una cámara climática a $20\pm 2^{\circ}\text{C}$ y $65\pm 5\%$ HR hasta peso constante tal y como especifican las respectivas normas de ensayo.

Los ensayos se realizaron según los protocolos de calidad establecidos en la norma UNE-EN ISO/IEC 17025 “Evaluación de la conformidad. Requisitos generales para la competencia de los laboratorios de ensayo y calibración” (AENOR 2005). En la siguiente tabla (Tabla 1) se relacionan todos los equipos de ensayo.

Tabla 1. Equipos utilizados.

Equipo	Rango	División de escala
Cámara de acondicionamiento	(15-30)°C (30-85)%HR	0,1°C 0,1%HR
Balanza COMECTA ESJ 200	0-200g	0,0001g
Máquina de ensayos Universal MICROTEST	0-5000N	0,1N
Calibre digital MITUTOYO DIGIMATIC	0-300mm	0,01mm
Medidor de altura MITUTOYO IDF	0-50mm	0,01mm
Estufa Memmert UFB 400	0-220°C	1°C

3.2. Red neuronal artificial

Se ha desarrollado una red neuronal artificial tipo perceptrón multicapa siguiendo la misma metodología descrita por los autores en sus anteriores trabajos de investigación (GARCÍA FERNÁNDEZ et al., 2012).

Un perceptrón multicapa está formado por una serie de nodos, denominados neuronas, conectados entre sí, de forma que el conocimiento adquirido se almacena en estas conexiones (PRIORE et al, 2002). Está compuesto de tres capas denominadas capa de entrada, capa oculta y capa de salida. La capa de entrada es la que recibe las señales de las variables de entrada y las distribuye a la siguiente capa, la capa oculta. La capa oculta, formada por una o más subcapas, es la encargada de realizar las operaciones matemáticas destinadas a obtener una salida. Finalmente la capa de salida es la encargada de mostrar el resultado de las operaciones realizadas en la capa oculta.

El número de neuronas de la capa de entrada está delimitado por la dimensión de los vectores de entrada. De la misma forma, el número de neuronas de la capa de salida está determinado por la dimensión del vector salida. Sin embargo no hay una regla definida para determinar si la capa oculta debe tener una o varias subcapas, ni cuántas neuronas debe tener cada una, por lo que el único método para configurar la capa oculta es mediante prueba y error (LIN & TSENG, 2000). Sí hay que tener en cuenta que un número muy pequeño de neuronas en las capas ocultas impide una buena generalización por parte de la red y que excesivo número de neuronas en las capas internas puede dificultar enormemente el proceso de aprendizaje sin mejorar sustancialmente los resultados finales (CHENG, 1995).

El diseño de una red neuronal del tipo perceptrón multicapa es un proceso complejo. No existe una regla definida para determinar la estructura interna de la red, sólo una serie de recomendaciones para su diseño, basadas en el número de datos disponibles (SHA, 2007) o en el tipo de configuración más deseable (VANSTONE & FINNIE, 2009). A esto hay que añadirle una serie de condiciones que se deben cumplir para que la red cumpla su función con las garantías suficientes, entre ellas evitar el sobreentrenamiento (BISHOP, 1995).

Para evitar el sobreentrenamiento y calcular el grado de fiabilidad de la red, el conjunto inicial de datos se ha dividido en tres subconjuntos de forma aleatoria: el subconjunto de entrenamiento, el de validación y el de comprobación en unas proporciones de 70-15-15%, lo que hace un total de 212 datos para el conjunto de entrenamiento, 44 datos para el conjunto de validación y 44 datos para el conjunto de comprobación. Estos porcentajes están dentro del rango de los utilizados por otros investigadores en el ámbito de los tableros derivados de la madera (COOK & WHITTAKER, 1992; COOK & CHIU, 1997; GARCÍA ESTEBAN et al., 2009)

Los dos primeros conjuntos se utilizaron durante la fase de entrenamiento y en la prevención del sobreentrenamiento respectivamente. El tercer subconjunto se utilizó para evaluar el grado de fiabilidad de la red (BISHOP, 1995).

El sobreentrenamiento de una red neuronal se manifiesta por un descenso del error en el conjunto de entrenamiento frente a un aumento en el conjunto de validación, es síntoma de que la red se está adaptando perfectamente a los datos del conjunto de entrenamiento pero ha perdido su capacidad de generalización (HAGAN et al. 1996; HAYKIN, 1999), para evitarlo se ha comparado cada 10 ciclos de entrenamiento el error en ambos conjuntos, dando por finalizado el proceso en el momento en que el error del conjunto de validación aumenta frente a un descenso en el conjunto de entrenamiento

Como función de transferencia se ha utilizado la tangente hiperbólica sigmoidea (Ecuación. 1), matemáticamente equivalente a la tangente hiperbólica pero que mejora el funcionamiento de la red (DEMUTH et al., 2002). Es la interconexión de estas funciones de transferencia no lineales lo que le confiere a la red su capacidad de generalización de las relaciones de las variables implicadas en el proceso (SAMARASINGHE et al, 2007)

$$f(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

f(x).- Valor de salida de la neurona.
x.- Valor de entrada de la neurona. Ecuación. (1)

Todos los valores de las variables, tanto las independientes como la dependiente, se normalizaron para una mejor efectividad de la función de transferencia (DEMUTH et al., 2002) (Ecuación. 2).

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

X': Valor después de normalización del vector *X*.
X_{min} y *X_{max}*: Valores máximo y mínimo del vector *X*. Ecuación. (2)

Como algoritmo de entrenamiento se ha utilizado el de retropropagación resiliente, el cuál es mejora notablemente los resultados para el caso de funciones de transferencia sigmoidea (DEMUTH et al., 2002).

Como criterio de aceptación de la red obtenida se ha utilizado la no existencia de diferencias significativas entre los datos reales y los simulados por la red para el conjunto de comprobación, tal y cómo viene definido en la normativa de ensayo UNE EN 326-2 (AENOR, 2011). Además, se ha utilizado el criterio de que debe existir un índice de correlación (*R*) superior a 0.70 entre los datos reales y los simulados, tal y cómo se reflejaba en la anterior norma de ensayo UNE EN 326-2 (AENOR, 2001) para la aceptación de los resultados de los ensayos obtenidos por un método alternativo al normalizado.

Como variables de entrada a la red se han utilizado la temperatura de las partículas y de la resina, contenido de humedad de la manta, porcentajes de adhesivo, porcentaje y tipo de aditivos, velocidad de la manta y temperatura de las prensas. La variable de salida fue la resistencia a la tracción perpendicular. Como paso previo al diseño de la red se realizó un análisis de componentes principales del vector de entrada, con el fin de determinar si existe algún tipo de correlación entre las variables de entrada y mejorar los resultados de la red (DEMUTH et al., 2002). Como criterio para la selección de las variables se tomó que su contribución a la variabilidad de la muestra fuera superior al 2% (DEMUTH et al., 2002).

4. Resultados

El análisis de componentes principales arrojó un nivel de contribución a la variabilidad de la muestras superior al 2% para cada una de las variables.

La arquitectura óptima para el perceptrón multicapa consta de dos capas ocultas con 5,4 y 4 neuronas cada una (figura. 2). La arquitectura cumple las condiciones para estar matemáticamente definida ya que se cuenta con 212 datos para el conjunto de entrenamiento frente a los 109 necesarios para obtener una red matemáticamente definida (SHA, 2007).

Los resultados obtenidos de correlación y estudio de diferencias significativas para la red neuronal artificial se reflejan en las tablas 2 y 3 y en las figura 3 y 4.

Tabla 2. Tabla ANOVA de los resultados experimentales de cohesión interna y los obtenidos mediante la red neuronal artificial para el conjunto de comprobación

Fuente	SS	g.l.	MS	F	p-valor
Columnas	0.001	1	0.001	0.07	0.786
Error	1.241	86	0.015		
Total	1.243	87			

Puesto que el p -valor es superior a 0.05 se puede concluir que no existen diferencias significativas entre los valores reales y los simulados mediante la red neuronal artificial con un nivel de confianza del 95% para el conjunto de comprobación.

Tabla 3. Resultado del proceso de diseño y comprobación de la red neuronal artificial

Propiedad	Fase	Estructura	Ecuación	R	R ²
Densidad	Entrenamiento	[8 5 4 4 1]	$Y=0.92 \cdot X+0.04$	0.96	0.93
	Validación		$Y=1.5 \cdot X+0.22$	0.86	0.74
	Comprobación		$Y=1.2 \cdot X+0.09$	0.87	0.76

El coeficiente de determinación (R^2) es superior a 0.75 lo cual indica que la red obtenida es capaz de explicar al menos el 75% de la variabilidad de las muestras.

Al ser el coeficiente de correlación superior a 0.70 y no existir diferencias significativas entre los valores reales y simulados para el conjunto de comprobación, se puede aceptar la red obtenida para simular la cohesión interna a partir de los parámetros de fabricación (AENOR, 2001, AENOR, 2011).




Figura 3. Gráfico LSD entre los valores simulados y los valores experimentales para el conjunto de comprobación.




Figura 4. Regresión entre los valores simulados y los valores experimentales para el conjunto de comprobación.

5. Discusión

Los resultados obtenidos se encuentran dentro del rango de valores obtenidos en otros estudios de modelización de productos derivados de la madera mediante redes neuronales artificiales.

Así COOK & WHITTAKER (1992) obtuvieron un valor de 0.70 y COOK & CHIU (1997) de 0.81 para el coeficiente de determinación de la resistencia interna de un tablero de partículas a partir de sus parámetros de fabricación, aunque en este último caso se utilizó otro tipo de red neuronal denominada red de base radial.

Así mismo, los autores del presente estudio obtuvieron coeficientes de correlación de 0.87 (GARCÍA FERNÁNDEZ et al., 2008), 0.98 (ESTEBAN et al., 2009) y 0.96-0.97 (ESTEBAN et al. 2010) en sus estudios realizados sobre otros tableros derivados de la madera, frente al 0.87 obtenido ahora.

Sin duda, esta mayor correlación obtenida en los estudios anteriores es debida a la utilización de datos obtenidos en un laboratorio de investigación frente a los datos del presente estudio, procedentes de la línea de producción diaria (KELLY, 1977).

Respecto a otros productos derivados de la madera, MANSFIEL et al. (2007) obtuvieron valores del coeficiente de determinación de 0.5 y 0.7 en su modelización del MOR y MOE de piezas de madera maciza de *Tsuga heterophylla* Raf., SAMARASINGHE et al. (2007) obtuvieron en la determinación de la resistencia a la fractura de probetas de madera maciza de *Pinus radiata* D. Don un valor del coeficiente de determinación de 0.62 y los autores del presente estudio obtuvieron valores de 0.75 en su estudio con probetas de grandes dimensiones de madera maciza de *Abies pinsapo* Boiss. (GARCÍA ESTEBAN et al., 2009) y 0.80 con probetas de grandes dimensiones de *Pinus radiata* D. Don (GARCÍA-IRUELA, 2016) frente al 0.76 del presente estudio.

6. Conclusiones

La red neuronal desarrollada es apta para predecir el valor de la resistencia a tracción a partir de los parámetros de fabricación del tablero.

Los resultados ofrecen una fiabilidad superior a la requerida por la normativa actual, UNE-EN 326-2 (AENOR, 2001, AENOR, 2011), por lo que este sistema puede considerarse como apto para el control en fábrica.

Por último se ha abierto una nueva vía de aplicación de las RNAs en el ámbito de los tableros derivados de la madera al aplicarlas por primera vez al control de la línea de producción.

7. Agradecimientos

Este estudio es parte del Proyecto de Investigación AGL2013-43510-R del Plan Estatal de Investigación, Desarrollo e Innovación Orientado a los Retos de la Sociedad (modalidad 1, "Retos e Investigación": Proyectos I+D+I), financiado por el Ministerio de Economía y Competitividad del Gobierno de España, en el marco del Plan Estatal de Investigación Científica y Técnica y de Innovación.

8. Bibliografía

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 1994a. Tableros de partículas y tableros de fibras. Determinación de la resistencia a la tracción perpendicular a las caras del tablero. Norma UNE-EN 319. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 1994b. Tableros derivados de la madera. Determinación del contenido de humedad. Norma UNE-EN 322. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 1994c. Tableros de partículas y tableros de fibras. Determinación de la densidad. Norma UNE-EN 323. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 2001. Tableros derivados de la madera. Muestreo, despiece e inspección. Parte 2: Control de la calidad en fábrica. Norma UNE-EN 326-2. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 2010. Tablero de Partículas. Especificaciones. Norma UNE-EN 312. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR), 2011. Tableros derivados de la madera. Muestreo, despiece e inspección. Parte 2: Ensayo inicial de tipo y control de producción en fábrica. Norma UNE-EN 326-2. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN (AENOR). 2005. Evaluación de la conformidad. Requisitos generales para la competencia de los laboratorios de ensayo y calibración. Norma UNE-EN ISO/IEC 17025. Madrid, España.

ASOCIACIÓN ESPAÑOLA DE NORMALIZACIÓN, 1995. Tableros derivados de la madera. Muestreo e inspección. Parte 1: Muestreo y despiece de probetas y expresión de los resultados de ensayo. Norma UNE-EN 326-1. AENOR, Madrid, España.

BARDAK, S.; TIRYAKI, S.; NEMLI, G.; AYDIN, A.; 2016. Investigation and neural network prediction of wood bonding quality based on pressing conditions. *Int. J. Adhes. Adhes.* 68: 115-123.

- BISHOP, C.M.; 1995. Neural networks for pattern recognition. Oxford University Press. 482pp. Oxford.
- CHENG, C.S.; 1995. A multi-layer neural network model for detecting changes in the process mean. *Comput. Ind. Eng.* 28: 51-61
- COOK, D.F.; CHIU, C.C.; 1997. Predicting the internal bond strength of particleboard, utilizing a radial basis function neural network. *Eng Appl Artif Intell.* 10:171-177.
- COOK, D.F.; RAGSDALE, C.T.; MAJOR, R.L.; 2000. Combining a neural network with a genetic algorithm for process parameter optimization. *Eng Appl Artif Intell.* 13:391-396.
- COOK, D.F.; WHITTAKER, A.D.; 1992. Neural network models for prediction of process parameters in wood products manufacturing. *1st Industrial Engineering Research Conference Proceedings.* 209-211.
- DE VEAUX, R.D.; SCHUMI, J.; SCHWEISBERG, J.; UNGAR L.H.; 1998. Prediction intervals for neural networks via nonlinear regression. *Technometrics.* 40(4): 273-282.
- DEMIRKIR, C.; OZSAHIN, S.; AYDIN, I.; COLAKOGLU, G.; 2013. Optimization of some panel manufacturing parameters for the best bonding strength of plywood. *Int. J. Adhes. Adhes.* 46: 14-20.
- DEMUTH, H.; BEALE, M.; HAGAN, M.; 2002. Neural Network Toolbox User's Guide, Version 4. The MathWorks Inc., 808pp. Natick.
- ESTEBAN, L.G.; FERNANDEZ, F.G.; DE PALACIOS, P.; RODRIGO, B.G.; 2010. Use of artificial neural networks as a predictive method to determine moisture resistance of particle and fiber boards under cyclic testing conditions (UNE-EN 321). *Wood Fiber Sci.* 42(3): 335-345.
- ESTEBAN, L.G.; GARCÍA FERNÁNDEZ, F.; DE PALACIOS, P.; CONDE, M.; 2009. Artificial neural networks in variable process control: application in particleboard manufacture. *Inv. Agrar.-Sist. Recursos Fores.* 18(1): 92-100.
- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO), 2010. ForesSTAT. <http://faostat.fao.org/site/626/DesktopDefault.aspx?PageID=626#ancor> [acceso: 16 de junio de 2016]
- GARCIA ESTEBAN, L.; GARCIA FERNÁNDEZ, F.; 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.
- GARCÍA FERNÁNDEZ, F.; DE PALACIOS, P.; ESTEBAN, L.G.; GARCIA-IRUELA, A.; GONZALEZ RODRIG,O B.; MENASALVAS, E.; 2012. Prediction of MOR and MOE of structural plywood board using artificial neural network and comparison with a multivariate regression model. *Compos. Pt. B-Eng.* 43: 3528-3533.
- GARCÍA FERNÁNDEZ, F.; ESTEBAN, L.G.; DE PALACIOS, P.; NAVARRO, N.; CONDE, M.; 2008. Prediction of standard particleboard mechanical properties utilizing an artificial neural network and subsequent comparison with a multivariate regression model. *Inv. Agrar.-Sist. Recursos Fores.* 17(2): 178-187.
- GARCÍA-IRUELA, A.; GARCIA FERNÁNDEZ, F.; GARCIA ESTEBAN, L.; DE PALACIOS, P.; SIMÓN, C.; ARRIAGA, F.; 2016. Comparison of modelling using regression techniques and an artificial neural network for obtaining the static modulus of elasticity of Pinus radiata D. Don. timber by ultrasound. *Compos. Pt. B-Eng.* 96: 112-118.

- HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. 1996. *Neural Network Design*. PWS Pub. Co. 802pp. Boston
- HAYKIN, S.; 1998. *Neural Networks: A Comprehensive Foundation*. Prentice Hall, 2nd edition. 842pp. Hamilton.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H.; 1989. Multilayer feedforward networks are universal approximators. *Neural Netw.* 2, 359-366.
- KELLY, M.W.; 1977. Critical literature review of relationships between processing parameters and physical properties of particleboard . U.S. Dept. of Agriculture, Forest Service, Forest Products Laboratory. 70pp. Madison.
- LIN, T.Y.; TSENG, C.H.; 2000. Optimum design for artificial networks: an example in a bicycle derailleur system. *Eng Appl Artif Intell.* 13: 3-14.
- MANSFIELD, S.D.; ILIADIS, L.; AVRAMIDIS, S.; 2007. Neural network prediction of bending strength and stiffness in western hemlock (*Tsuga heterophylla* Raf.). *Holzforschung* 61:707-716.
- MORRIS, A.J.; MONTAGUE G.A.; WILLIS M.J.; 1994. Artificial neural networks: Studies in process modeling and control. *Trans I ChemE.* 72(A): 3-19
- OZSAHIN, S.; 2012. The use of an artificial neural network for modeling the moisture absorption and thickness swelling of oriented strand board. *BioResources.* 7(1): 1053-1067.
- PRIORE, P.; DE LA FUENTE, D.; PINO, R.; PUENTE, J.; 2002. Utilización de las redes neuronales en la toma de decisiones. Aplicación a un problema de secuenciación. *Anales de Mecánica y Electricidad.* 79(6): 28-34.
- SAMARASINGHE, S.; KULARISI, D.; JAMIESON, T.; 2007. Neural networks for predicting fracture toughness of individual wood samples. *Silva. Fenn.* 41(1): 105-122.
- 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.
- VANSTONE, B.; FINNIE, G.; 2009. An empirical methodology for developing stockmarket Trading Systems using artificial neural Networks. *Expert Syst. Appl.* 36:6668-6680.