



**2025** | **16-20**  
GIJÓN | JUNIO

9º CONGRESO **FORESTAL** ESPAÑOL

**9CFE-1502**

---

Organiza





## 1. Introducción

La madera es un material con gran potencial en la industria de la construcción debido a sus características sostenibles, renovables y de bajo impacto ambiental, entre otras. Sin embargo, para garantizar la calidad y seguridad de las estructuras de madera, es esencial contar con una caracterización y clasificación precisas de sus propiedades físico-mecánicas. En este contexto, una de las propiedades más importantes es la resistencia a flexión de los elementos estructurales de madera, por ello su predicción es esencial para sus aplicaciones [1-2]. Tradicionalmente, la caracterización de la resistencia a flexión ha requerido ensayos destructivos, que implican la rotura de las muestras, esto aumenta los costes y limita la cantidad de material que puede evaluarse. Por ello, el uso de técnicas no destructivas (NDT) ha ganado relevancia en los últimos años como un método eficiente y sostenible para evaluar las propiedades de la madera sin comprometer su integridad. Existen diversos equipos no destructivos portátiles o de tipo estático, como las máquinas de clasificación mecánica [3]. Varios autores han llevado a cabo la caracterización de las propiedades de varias especies enfocadas en su uso estructural a través de la clasificación mecánica [4-6]. Otra manera tradicional de clasificación de madera estructural es la clasificación visual de acuerdo a las normas UNE 56544 o UNE 56546 para coníferas o frondosas [7-8], respectivamente.

Las NDT no sólo permiten estimar la resistencia de la madera sino también otros parámetros clave, como el Módulo de Elasticidad (MOE) o la densidad mediante la aplicación de múltiples métodos como ultrasonidos, vibración u ondas de impacto, entre otros [4,9-11]. Los parámetros obtenidos a través de las NDT pueden emplearse de forma directa o indirecta como variables predictoras con diferentes técnicas estadísticas, desde modelos de regresión lineal simple (SLR) hasta técnicas más avanzadas como la regresión lineal múltiple (MLR) y modelos no lineales, como las redes neuronales artificiales (ANN) o el método de Random Forest [12-15]. Estas técnicas permiten predecir la resistencia a flexión o módulo de ruptura (MOR) con errores de predicción reducidos. Sin embargo, uno de los mayores retos en la ingeniería de la madera de estos modelos es encontrar un equilibrio entre la precisión y la complejidad del modelo. La proyección de modelos simples puede no incluir todas las variables que expliquen adecuadamente la variable a predecir, mientras que modelos excesivamente complejos, además de suponer un incremento en el coste, pueden llevar al conocido efecto de sobreajuste, lo que impide generalizar un modelo al aplicar nuevos conjuntos de datos [16].

## 2. Objetivos

El presente estudio tiene como objetivo evaluar la capacidad predictiva de diferentes modelos estadísticos, lineales y no lineales, para la estimación del MOR en piezas de tamaño estructural de madera de *Pinus pinaster* Aiton a partir de los datos obtenidos mediante NDT.

## 3. Metodología

Para el estudio se utilizaron 491 piezas de *Pinus pinaster* Aiton de tamaño



estructural, obtenidas de diferentes aserraderos de Galicia. Una vez secas, fueron clasificadas visualmente de acuerdo con la norma UNE 56544 [8]. Las características de las piezas ensayadas se muestran en la Tabla 1. Para valorar la influencia de los nudos, se utilizó la suma de los diámetros de los nudos presentes en la zona de la pieza con mayor concentración de los mismos (ckdr) [17].

El MOR de las piezas se determinó mediante el ensayo de flexión hasta rotura, siguiendo la norma UNE-EN 408 [18] y calculado según UNE-EN 384 [19]. Se utilizaron diferentes NDT para estimar el MOR, en primer lugar, Microsecond Timer (ms, Fakopp Enterprise, Agfalva, Hungría) y Sylvatest Duo (us, Concept Bois Structure, Montandon, Francia), ambos equipos basados en la medición del tiempo de vuelo de una onda de choque a través de la pieza, con frecuencias de onda similares (22 kHz y 23 kHz, respectivamente). Con cada uno de estos dispositivos se obtuvo la velocidad de la onda y el MOE realizando dos tipos de medición, indirecta (con los dos transductores situados en los extremos de la misma cara de la pieza, di\_vel, di\_moe) y directa (con los transductores situados en las testas, dd\_vel, dd\_moe). También se utilizó el equipo Portable Lumber Grader (plg, Fakopp Enterprise Bt, Agfalva, Hungría) para determinar la frecuencia longitudinal de resonancia, así como la velocidad de la onda (plg\_vel), el módulo de elasticidad (plg\_moe) y la densidad (plg\_den). Por último, se utilizó un equipo de clasificación mecánica (MG, Cook-Bolinder SG-AF machine, Tecmach Ltd, Reino Unido) con el que se obtuvieron dos módulos de elasticidad, uno en el punto más débil detectado por la máquina (moe\_funo) y otro en el punto de rotura (moe\_frot). Adicionalmente, se midieron la densidad y la humedad, de acuerdo con la norma UNE-EN408 [18].

**Tabla 1. Lotes, clasificación visual, MOR y densidad de las piezas ensayadas**

1	63	150 × 50 × 3500	30,2	39,7	30,2	62,6	583,8
2	90	100 × 50 × 2500	57,8	28,9	13,3	58,1	584,0
3	86	150 × 40 × 3500	2,3	24,4	73,3	49,1	559,1
4	77	200 × 70 × 4000	35,1	49,4	15,6	62,0	574,8
5	84	150 × 70 × 3500	19,0	44,0	36,9	51,1	567,8
6	91	200 × 50 × 4000	19,8	37,4	42,9	21,2	555,2
Total	491	27,3	36,9	35,8	55,2	570,2	

Con los métodos descritos se obtuvieron 17 variables para predecir el MOR: cuatro con el ms (ms\_dd\_vel, ms\_di\_vel, ms\_dd\_moe y ms\_di\_moe), cuatro con el sd (us\_dd\_vel, us\_di\_vel, us\_dd\_moe y us\_di\_moe), tres con el PLG (plg\_vel, plg\_moe, plg\_den) y dos con el MG (moe\_funo y moe\_frot), además de la clasificación visual, el ckdr, la humedad y la densidad corregida al 12%.



Se probaron diferentes métodos estadísticos para predecir el MOR. En primer lugar, una regresión lineal simple (SLR) con cada una de las variables estudiadas. Después se utilizaron modelos multivariable, comenzando por una regresión lineal múltiple (MLR) en la que se utilizaron todas las variables para ir eliminando sucesivamente, y de una en una, aquellas que provocaban un menor incremento del error de predicción. En cuanto a los modelos no lineales, se utilizaron diferentes tipos. Se creó una red neuronal (ANN) basada en el algoritmo de propagación hacia atrás [20] para crear un perceptrón de 4 neuronas en una única capa, una estructura similar a la utilizada en estudios previos sobre propiedades mecánicas de la madera [21-22]. Se utilizó el algoritmo de  $k$  vecinos más próximos ( $k$ -NN) asignando a cada muestra el error de predicción correspondiente a la ponderación de las  $k$  muestras más próximas [23]. Para asignar los diferentes pesos a cada una de las muestras vecinas, se utilizaron los 26 vecinos próximos con ponderación  $1/\text{distancia}$  ( $k$ -NN). También se utilizaron los algoritmos Random Tree, que genera árboles de decisión de forma aleatoria, Random Forest que genera conjuntos de árboles de decisión [24] y KStar, que realiza agrupamientos de forma aleatoria mediante clústers [25].

Para valorar el error de predicción se utilizó la raíz del error cuadrático medio (RMSE), una medida que compara los valores estimados con los observados y establece la precisión en la predicción de cada modelo, en lugar de utilizar el coeficiente de determinación,  $R^2$ , que se emplea para cuantificar la variabilidad [26].

Un problema inherente a los modelos multivariable es el sobreajuste [27] que ocurre cuando un modelo también ajusta el ruido existente en los datos. Un modelo predictivo con sobreajuste arrojará errores engañosamente bajos ya que el algoritmo se ajusta muy bien al conjunto de datos de prueba pero no es válido para otro conjunto de datos. El sobreajuste se puede evitar creando el modelo con un conjunto de datos y probando su validez con un conjunto de datos diferente. En este estudio, se utilizó un método de validación cruzada con 10 carpetas y 10 repeticiones [28,29]. Las muestras se distribuyeron aleatoriamente en 10 subconjuntos (carpetas), probando con las muestras de una carpeta el modelo creado con las muestras de las otras 9 y repitiendo el proceso 10 veces, de modo que cada carpeta fue utilizada una vez para probar el modelo. La división en carpetas se repitió 10 veces, repartiendo las muestras de forma aleatoria en 10 carpetas cada vez. De esta forma, para cada modelo predictivo se obtuvieron 100 valores de RMSE.

Las comparaciones de RMSE entre los algoritmos se realizaron con el software de minería de datos WEKA (Waikato University, Hamilton, Nueva Zelanda), aplicando el test-T [20]. Las comparaciones entre las variables de entrada se llevaron a cabo utilizando el software estadístico R 3.6.1 (The R Foundation, Viena, Austria). Dado que los datos de RMSE obtenidos mediante validación cruzada no eran estadísticamente independientes, se aplicó el test no paramétrico de Kruskal-Wallis. En aquellos casos en los que se detectaron diferencias estadísticamente significativas se realizó un análisis post hoc con el test no paramétrico de Dunn y el ajuste de Bonferroni [30]. Se aplicó un nivel de significación de 0,05 en todos los

casos.

#### 4. Resultados

Los errores de predicción del MOR mediante regresión lineal univariable (SLR) a partir de cada una de las variables estudiadas se muestran en la Tabla 2.

**Tabla 2. Error de predicción del MOR de las variables estudiadas**

plg_moe	13,7	a
ms_dd_moe	14,9	b
us_dd_moe	15,0	b
moe_funo	15,2	bc
ms_di_moe	15,3	bc
densidad	15,4	bc
plg_den	15,5	bcd
moe_frot	15,5	bcd
us_di_moe	15,6	bcd
ckdr	15,8	cd
plg_vel	16,2	de
ms_dd_vel	16,7	ef
us_dd_vel	16,8	ef
ms_di_vel	17,0	efg
us_di_vel	17,2	fg
humedad	17,8	g

No se detectaron diferencias significativas entre los valores marcados con la misma letra ( a, b, c, d, e, f, g ).

El MOE calculado con el PLG (plg\_moe) resultó la variable que proporciona un error significativamente más bajo que el del resto. No se incluyó la clasificación visual por tratarse de una variable nominal.

Los errores de predicción obtenidos mediante MLR se pueden observar en la Tabla 3. El error obtenido con dos variables (plg\_moe y us\_di\_vel) fue significativamente menor que el obtenido solo con una (plg\_moe). La adición de más variables no



supuso una disminución significativa del error.

**Tabla 3. Error de predicción del MOR de las variables estudiadas mediante MLR**

Todas	17	13,4	ab		
<b>visual, moe_funo, moe_frot, us_di_vel, plg_moe</b>	2,1·(visual=ME2,ME1) + 0,8154·(visual=ME1) + 0,0016·moe_funo	- 0,0015·moe_frot - 0,0146·us_di_vel + 0,0057·plg_moe + 66,93	5	13,2	b
<b>moe_funo, moe_frot, us_di_vel, plg_moe</b>	0,0017·moe_funo - 0,0018·moe_frot - 0,0152·us_di_vel	+ 0,006·plg_moe + 70,13	4	13,0	b
<b>moe_frot, us_di_vel, plg_moe</b>	- 0,0005·moe_frot - 0,0151·us_di_vel + 0,0061·plg_moe + 71,37	3	13,1	b	
<b>us_di_vel, plg_moe</b>	- 0,0155·us_di_vel + 0,0058·plg_moe + 71,18	2	13,0	b	
<b>plg_moe</b>	0,0041·plg_moe + 10,42	1	13,6	a	
No se detectaron diferencias significativas entre los valores marcados con la misma letra ( a, b ).					

En cuanto a los modelos no lineales, los errores en la predicción del MOR se pueden observar en la Figura 1. Se ha añadido también el modelo univariable basado en plg\_moe como referencia de comparación. Los errores de predicción obtenidos mediante modelos no lineales no mejoraron los obtenidos con modelos lineales, y ello a pesar de su mayor complejidad.

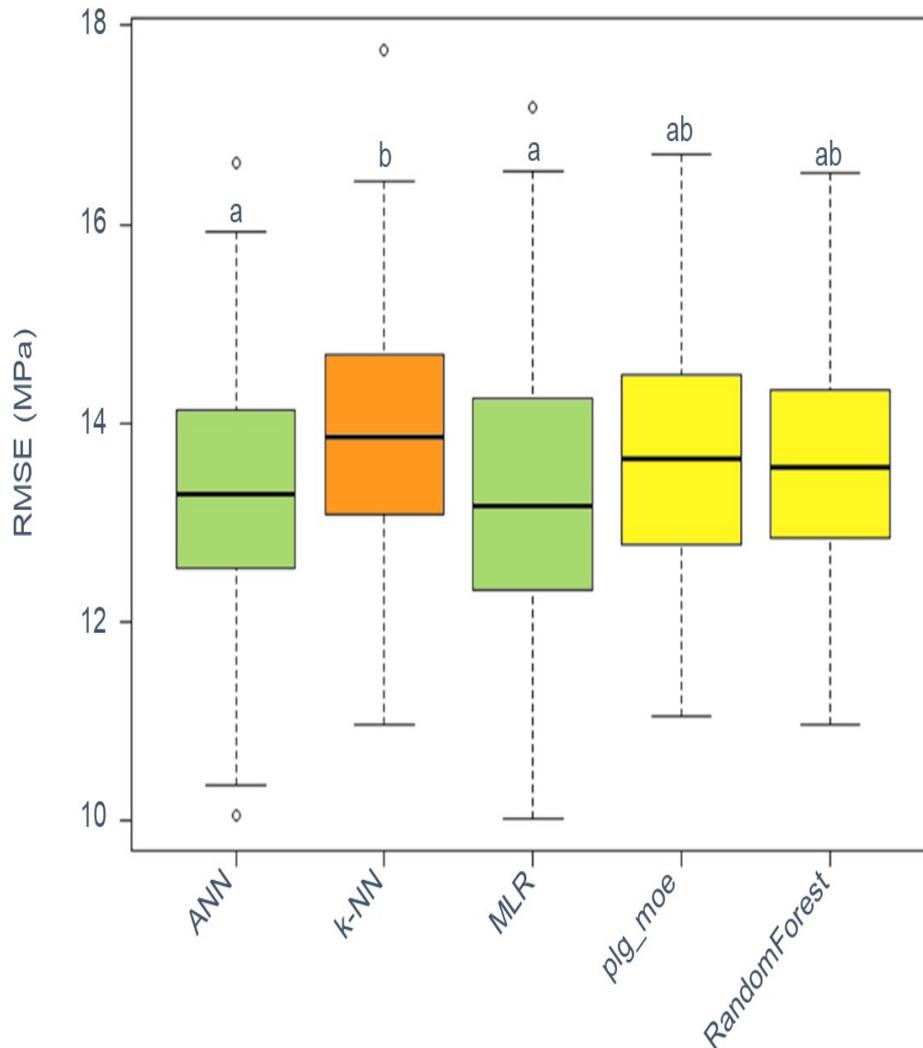


Figura 1. Error de predicción del MOR mediante modelos no lineales. (No se detectaron diferencias significativas entre los valores marcados con la misma letra).

Los análisis anteriores se realizaron a partir de todas las variables obtenidas con todos los aparatos. Por último, se realizó un análisis similar suponiendo que solo se dispone de un dispositivo, el PLG, ya que fue el que obtuvo mejores resultados. La intención fue simular la situación de una industria en la que solo se dispone de un aparato de clasificación. La Figura 2 muestra el análisis realizado a partir de los datos obtenidos con el PLG (plg\_vel, plg\_moe, plg\_den) además de la humedad, la clasificación visual y el ckdr. De nuevo, los modelos multivariable no lineales no mejoraron el error obtenido con los modelos lineales.

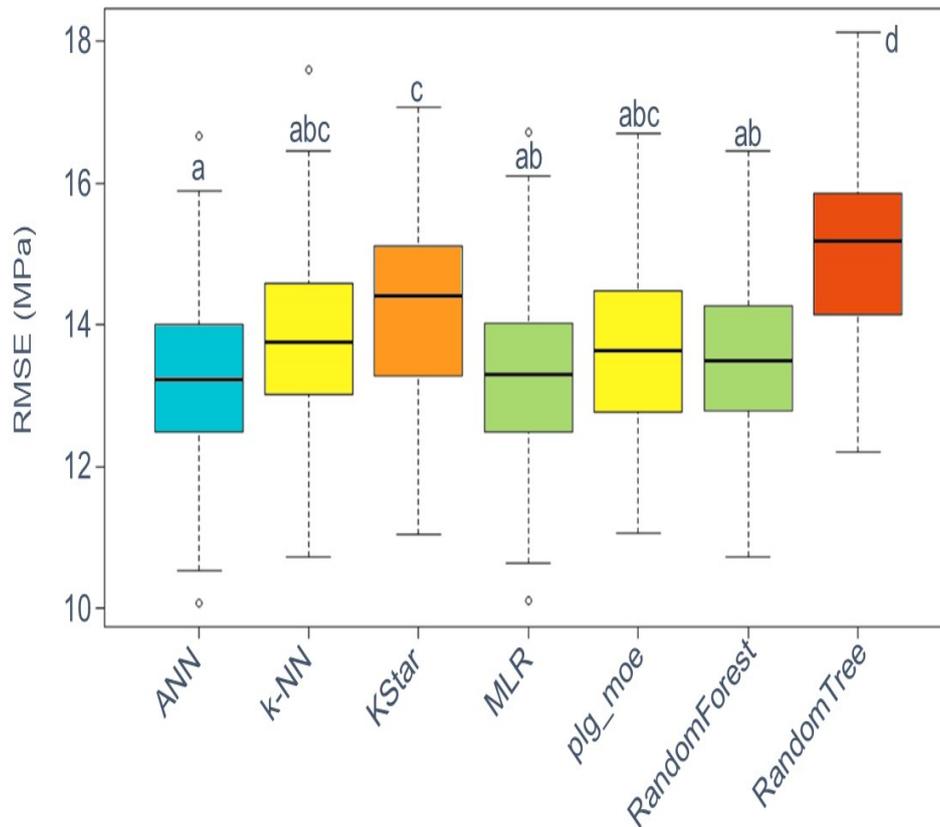


Figura 2. Error de predicción del MOR suponiendo que solo se dispone de un dispositivo, el PLG (No se detectaron diferencias significativas entre los valores marcados con la misma letra).

## 5. Discusión

El MOE obtenido con el PLG (plg\_moe) resultó la variable que permitió predecir el MOR con un error más reducido. Los errores en la predicción del MOR a partir de una sola variable se situaron en torno al 25%. Estos resultados coinciden con lo que muestran los estudios previos. En la predicción del MOR a partir de NDT, FERNÁNDEZ-SERRANO y VILLASANTE [1], observaron un error del 29% en ensayos realizados con *Pinus sylvestris* L., ARRIAGA *et al.* [31], trabajando con *Pinus radiata*, hallaron una correlación débil ( $r^2=0,46$ ) entre las variables obtenidas mediante NDT y el MOR, mientras que FRANÇA *et al.* [32], en ensayos realizados con diferentes especies de pino (*southern pine*) encontraron un error del 27%.

Los modelos lineales multivariable, al combinar las variables obtenidas con diferentes dispositivos, disminuyeron significativamente el error de predicción. Sin embargo, esta disminución, de 0,6MPa, supuso solo el 1% del valor del MOR a predecir. Esta ligera disminución del error también se refleja en otros estudios.



FERNÁNDEZ-SERRANO y VILLASANTE [1] observaron una disminución del error de 2MPa (5%), FRANÇA *et al.* [32] vieron como el error descendía en 1,6MPa (3%), mientras que ARRIAGA *et al.* [31] comprobaron que el coeficiente de correlación experimentaba un ligero aumento ( $r^2=0,61$ ).

A pesar de su mayor complejidad, los modelos no lineales no mejoraron la predicción del MOR realizada con los modelos lineales. FERNÁNDEZ-SERRANO y VILLASANTE [1], así como VILLASANTE *et al.* [33] no encontraron diferencias significativas entre ambos tipos de modelos predictivos. HAFTKHANI *et al.* [34] comprobaron que la utilización de ANN disminuía el error en 0,4 MPa respecto a los modelos lineales en ensayos realizados con *Abies* sp. Sin embargo, otros autores sí observaron que la predicción del MOR mejoraba al utilizar modelos basados en ANN. FATHI *et al.* [35], en madera de chopo euroamericano (*Populus x canadensis* Moench), o MANSFIELD *et al.* [36] con *Tsuga heterophylla* (Raf.) Sarg., en ambos casos con piezas pequeñas libres de defectos.

## 6. Conclusiones

De los diferentes dispositivos utilizados para valorar el MOR, el PLG fue el que proporcionó un error de predicción significativamente menor que el resto. No obstante, a pesar de esa diferencia significativa, el incremento del error utilizando otros equipos resultó reducido. De este modo, otras variables como el coste, la facilidad de uso o la disponibilidad pueden influir decisivamente en la elección del equipo idóneo.

El error de predicción obtenido con modelos multivariados y, por lo tanto, más complejos, ya fueran lineales o no lineales, mejoró significativamente la predicción obtenida con una sola variable. Sin embargo la mejora fue tan reducida en términos absolutos que pone en duda su utilidad real, porque se realiza a costa de un incremento importante del coste y el tiempo de ensayo.

## 7. Bibliografía

[1] FERNÁNDEZ-SERRANO, Á.; VILLASANTE, A.; 2022. Modulus of rupture prediction in *Pinus sylvestris* with multivariate models constructed with resonance, ultrasound, and wood heterogeneity variables. *Bioresources* 17 1106–1119. <https://doi.org/10.15376/biores.17.1.1106-1119>

[2] ÍÑIGUEZ-GONZÁLEZ, G.; ARRIAGA, F.; BARRETT, J.D.; ESTEBAN, M.; 2007. Visual grading of large structural coniferous sawn timber according to Spanish standard UNE 56544. *For. Prod. J.* 57 45–50.

[3] KRZOSEK, S.; NOSKOWIAK, A.; PAJCHROWSKI, G.; 2022. Comparative studies of visual and machine strength grading of pine structural sawn timber. *Drewno* 65



31–40. <https://doi.org/10.12841/wood.1644-3985.354.03>

[4] RIDLEY-ELLIS, D.; GIL-MORENO, D.; HARTE, A.M.; 2022. Strength grading of timber in the UK and Ireland in 2021. *Int. Wood Prod. J.* 13 127–136. <https://doi.org/10.1080/20426445.2022.2050549>

[5] FERNÁNDEZ-GOLFÍN, J.I.; DIEZ, M.R.; HERMOSO, E.; CONDE, M.; 2004. Mechanical characterization of timber from Spanish provenances of laricio pine according to European standards. *Wood Sci. Technol.* 38 25–34. <https://doi.org/10.1007/s00226-003-0215-3>

[6] GONÇALVES, A.M.; CANDEIAS, P.; GUERREIRO, L.; GOMES FERREIRA, J.; CAMPOS COSTA, A.; 2019. Characterization of timber masonry walls with dynamic tests. *Int. J. Archit. Herit.* 13 298–313. <https://doi.org/https://doi.org/10.1080/15583058.2018.1436727>

[7] UNE 56544; 2022. Clasificación visual de la madera aserrada para uso estructural. Madera de coníferas. Madrid, Spain: AENOR, Asociación Española de Normalización y Certificación.

[8] UNE 56546; 2022. Clasificación visual de la madera aserrada para uso estructural. Madera de frondosas. Madrid, Spain: AENOR, Asociación Española de Normalización y Certificación.

[9] ROSS, R.J.; 2015. Nondestructive evaluation of wood: second edition. *General Technical Report FPL-GTR-238*. Madison, WI, USA: Department of Agriculture, Forest Service, Forest Products Laboratory.

[10] BUKAUSKAS, A.; MAYENCOURT, P.; SHEPHERD, P.; SHARMA, B.; MUELLER, C.; WALKER, P.; Bregulla, J.; 2019. Whole timber construction: a state of the art review. *Constr. Build. Mater.* 213 748–769. <https://doi.org/10.1016/j.conbuildmat.2019.03.043>

[11] LLANA, D.F.; ÍÑIGUEZ-GONZÁLEZ, G.; DÍEZ, M.R.; ARRIAGA, F.; 2020. Nondestructive testing used on timber in Spain: a literature review. *Maderas Cienc. y Tecnol.* 22 133–156. <https://doi.org/10.4067/s0718-221x2020005000201>

[12] BAAR, J.; TIPPNER, J.; RADEMACHER, P.; 2015. Prediction of mechanical properties – modulus of rupture and modulus of elasticity – of five tropical species by nondestructive methods. *Maderas Cienc. y Tecnol.* 17 239–252. <https://doi.org/10.4067/S0718-221X2015005000023>

[13] FAGGIANO, B.; GRIPPA, M.R.; CALDERONI, B.; 2013. Non-destructive tests and bending tests on chestnut structural timber. *Adv. Mater. Res.* 778 167–174.



<https://doi.org/10.4028/www.scientific.net/AMR.778.167>

[14] TANAKA, T.; NAGAO, H.; KATO, H.; 1996. A preliminary investigation on evaluation of strength of soft wood timbers by neural network. *Proceeding 10th Int. Symp. Nondestruct. Test. Wood*, Lausanne, 323–329.

[15] GARCÍA-IRUELA, A.; FERNÁNDEZ, F.G.; ESTEBAN, L.G.; 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. Part B Eng.* 96 112–118. <https://doi.org/10.1016/j.compositesb.2016.04.036>

[16] LEVER, J.; KRZYWINSKI, M.; ALTMAN, N.; 2016. Points of significance: model selection and overfitting. *Nat. Methods* 13 703–704. <https://doi.org/10.1038/nmeth.3968>

[17] ARRIAGA, F.; IÑIGUEZ-GONZALEZ, G.; ESTEBAN, M.; DIVOS, F.; 2012. Vibration method for grading of large cross-section coniferous timber species. *Holzforschung* 66 381–387. <https://doi.org/10.1515/HF.2011.167>

[18] UNE-EN 408:2011+A1; 2012. Estructuras de madera. Madera aserrada y madera laminada encolada para uso estructural. Determinación de algunas propiedades físicas y mecánicas. Bruselas, Bélgica: Comité Europeo de Normalización.

[19] UNE-EN 384:2016+A2; 2023. Madera estructural. Determinación de los valores característicos de las propiedades mecánicas y la densidad. Bruselas, Bélgica: Comité Europeo de Normalización.

[20] WITTEN, I.H.; FRANK, E., HALL, M.A.; 2011. Data Mining: Practical Machine Learning Tools and Techniques. Morgan Kaufmann. 621 p. San Francisco. <https://doi.org/10.1016/b978-0-12-804291-5.00024-6>

[21] TIRYAKI, S.; HAMZAÇEBI, C.; 2014. Predicting modulus of rupture (MOR) and modulus of elasticity (MOE) of heat treated woods by artificial neural networks. *Meas J Int Meas Confed* 49 266–74. <https://doi.org/10.1016/j.measurement.2013.12.004>

[22] HAFTKHANI, A.R.; ABDOLI, F.; SEPEHR, A.; MOHEBBY, B.; 2021. Regression and ANN models for predicting MOR and MOE of heat-treated fir wood. *J Build Eng* 42 102788. <https://doi.org/10.1016/j.jobe.2021.102788>

[23] AHA, D.W.; KIBLER, D.; ALBERT, M.K.; 1991. Instance-Based Learning



Algorithms. *Mach Learn* 6 37–66.

[24] BREIMAN, L.; 2001. Random Forests. *Mach Learn* 45 5–32.  
<https://doi.org/10.1023/A:1010933404324>

[25] ALJAZZAR, H.; LEUE, S.; 2011. K\*: A Heuristic Search Algorithm for Finding the k Shortest Paths. *Artif Intell* 175 2129–2154.  
<https://doi.org/10.1016/j.artint.2011.07.003>

[26] ALEXANDER, D.L.J.; TROPSHA, A.; WINKLER, D.A.; 2015. Beware of R<sup>2</sup>: Simple, Unambiguous Assessment of the Prediction Accuracy of QSAR and QSPR Models. *J Chem Inf Model* 55 1316–22. <https://doi.org/10.1021/acs.jcim.5b00206>

[27] CHEN, W.C.; TSENG, L.Y.; WU, C.S.; 2014. A unified evolutionary training scheme for single and ensemble of feedforward neural network. *Neurocomputing* 143 347–61. <https://doi.org/10.1016/j.neucom.2014.05.057>.

[28] FAYDI, Y.; BRANCHERIAU, L.; POT, G.; COLLET, R.; 2017. Prediction of oak wood mechanical properties based on the statistical exploitation of vibrational response. *BioResources* 12 5913–27. <https://doi.org/10.15376/biores.12.3.5913-5927>.

[29] HASHIM, U.R.; HASHIM, S.Z.M.; MUDA, A.K.; 2016. Performance evaluation of multivariate texture descriptor for classification of timber defect. *Optik* 127 6071–80. <https://doi.org/10.1016/j.ijleo.2016.04.005>.

[30] BRUNETTI, M.; BURATO, P.; CREMONINI, C.; NEGRO, F.; NOCETTI, M.; ZANUTTINI, R.; 2016. Visual and machine grading of larch (*Larix decidua* Mill.) structural timber from the Italian Alps. *Mater Struct* 49 2681–8. <https://doi.org/10.1617/s11527-015-0676-5>.

[31] ARRIAGA, F.; MONTON, 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* 68 299–305. <https://doi.org/10.1515/hf-2013-0087>.

[32] FRANÇA, F.J.N.; SEALE, R.D.; SHMULSKY, R.; FRANÇA, T.S.F.A.; 2019. Modeling mechanical properties of 2 by 4 and 2 by 6 southern pine lumber using longitudinal vibration and visual characteristics. *For Prod J* 68 286–294. <https://doi.org/10.13073/FPJ-D-17-00069>.

[33] VILLASANTE, A.; IÑIGUEZ-GONZALEZ, G.; PUIGDOMENECH, L.; 2019. Comparison of various multivariate models to estimate structural properties by means of non-destructive techniques (NDTs) in *Pinus sylvestris* L. timber.



*Holzforschung* 73 331–338. <https://doi.org/10.1515/hf-2018-0103>.

[34] HAFTKHANI, A.R.; ABDOLI, F.; SEPEHR, A.; MOHEBBY, B.; 2021. Regression and ANN models for predicting MOR and MOE of heat-treated fir wood. *J Build Eng* 42 102788. <https://doi.org/10.1016/j.jobe.2021.102788>.

[35] FATHI, H.; NASIR, V.; KAZEMIRAD, S.; 2020. Prediction of the mechanical properties of wood using guided wave propagation and machine learnin. *Constr Build Mater* 262 120848. <https://doi.org/10.1016/j.conbuildmat.2020.120848>

[36] 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. <https://doi.org/10.1515/HF.2007.115>