

APROXIMACIONES NEURONALES PARA LA MODELIZACIÓN DEL CRECIMIENTO DIARIO DEL ALCORNOQUE (*QUERCUS SUBER* L.) EN UNA DEHESA DEL SUROESTE DE ESPAÑA (HINOJOS, HUELVA)

Javier Vázquez Piqué, Raúl Tapias Martín, Juan Carlos Gutiérrez-Estrada e Inmaculada Pulido-Calvo

Departamento de Ciencias Agroforestales. Escuela Politécnica Superior. Campus La Rábida. Universidad de Huelva. 21819-PALOS DE LA FRONTERA (Huelva-España) Correo electrónico: jpique@uhu.es

Resumen

En este estudio se analiza el crecimiento diario de dos alcornoques situados en una parcela de Hinojos (Huelva) en el año 2004. Los datos de crecimiento se adquirieron cada 15 minutos mediante galgas extensiométricas que se situaron sobre y bajo corcho de cada uno de los individuos. Las variables climáticas y edáficas que intervienen se recogieron cada 15 minutos mediante dispositivos instalados en la parcela. Para cada día se calculó la máxima contracción diaria, la máxima dilatación diaria y el crecimiento diario y se calcularon los valores medios, máximos y mínimos de las variables edáficas y climáticas para esos periodos. Con éstos se pretendió la caracterización de los parámetros de crecimiento de los dos alcornoques seleccionados mediante el uso de regresiones múltiples y de redes neuronales computacionales, con los datos edáficos y climáticos como variables independientes. Los mejores resultados se consiguieron con los modelos neuronales con correlaciones superiores a 0,6 y magnitudes de error aceptables. Un análisis de sensibilidad mostró que las variables que influyeron de forma más significativa en la estimación de los parámetros de crecimiento fueron las temperaturas del aire y el contenido en humedad del suelo.

Palabras clave: *Modelos heurísticos, Regresión lineal múltiple, Galgas extensiométricas, Variables climáticas, Variables edáficas*

INTRODUCCIÓN

Las masas de alcornoque han sido gestionadas tradicionalmente con el objetivo principal de extracción de corcho. De esta forma, la mayor parte de los modelos que se han realizado para la gestión de este tipo de masas se centran únicamente en la estimación de la producción de corcho, prestándose escasa atención a otros aspectos básicos como la evolución del crecimiento en diámetro y los factores que influyen dicho crecimiento. Un conocimiento más exhaustivo

del crecimiento de la especie es necesario para la utilización de criterios técnicos a la hora de definir aspectos básicos de su selvicultura y ordenación (VÁZQUEZ Y PEREIRA, 2005).

Además el conocimiento detallado del crecimiento de las especies forestales y su relación con factores ambientales supone un avance importante en la gestión sostenible de las masas y permite mejorar el conocimiento del papel que juegan éstas como fijadoras de CO₂ atmosférico o realizar simulaciones de crecimiento de las especies frente a distintos escenarios de cambio

climático. A pesar del interés de conocer el crecimiento, los estudios realizados para profundizar en las relaciones crecimiento-factores ambientales al nivel de detalle y a escala intra-anual o incluso diaria son escasos actualmente (DOWNES *et al.*, 1999; DESLAURIERS *et al.*, 2003).

En el presente trabajo se utilizan modelos de Regresiones Lineales Múltiples (RLM) y de Redes Neuronales Computacionales (RNC) para la caracterización del crecimiento de dos alcornoques situados en una parcela de Hinojos (Huelva, suroeste de España). Se analiza la influencia sobre el crecimiento de variables edáficas y climáticas.

MATERIAL Y MÉTODOS

Identificación de las variables de los modelos

En este estudio se analiza el crecimiento diario de dos alcornoques (A13 y A51) situados en una parcela de Hinojos (Huelva) en el año 2004. Los datos de crecimiento se adquirieron cada 15 minutos durante todos los días del año 2004 mediante galgas extensiométricas que se situaron sobre y bajo corcho de cada uno de los individuos y que miden la contracción o dilatación que experimenta el tronco del árbol con una precisión de 2 mm. Las variables climáticas (precipitación, radiación, temperatura del aire, velocidad del viento, humedad relativa, humedad de hoja) y edáficas (temperatura del suelo, humedad del suelo a 10, 30, 60, 90 y 120 cm de profundidad) también se recogieron cada 15 minutos durante todos los días del año 2004 mediante sensores instalados en la parcela.

Para cada día se calculó la máxima contracción diaria, máxima dilatación diaria y el crecimiento diario (Figura 1) y se obtuvieron los valores diarios medios, máximos y mínimos de las variables climáticas y edáficas para esos períodos de crecimiento.

Redes Neuronales Computacionales

Una red neuronal es un modelo heurístico que copia la estructura de un sistema neuronal biológico con el fin de alcanzar una funcionalidad similar. El procesador elemental o neurona es un dispositivo simple de cálculo que, a partir de un vector de entrada del exterior, proporciona una respuesta o salida. En general, una red neuronal consiste en el establecimiento de un conjunto de nodos o neuronas agrupadas en varias capas e interconectadas entre sí (capa de entrada, capas ocultas y capa de salida). Las conexiones que unen a las neuronas tiene asociado un peso numérico y el aprendizaje se realiza con la actualización de tales pesos. Se denomina época al período de tiempo que comprende todas las iteraciones realizadas al presentar todos los patrones (conjunto de datos de entrenamiento o calibración) una sola vez. La actualización de los pesos se realiza al final de cada época.

Para la calibración y validación de los modelos se ha utilizado el módulo correspondiente del software STATISTICA 6.0 (STATSOFT, INC., 1984-2002). El algoritmo de aprendizaje utilizado fue el supervisado de segundo orden de Levenberg-Marquardt (LM) (SHEPHERD, 1997). El algoritmo de aprendizaje de retropropagación estándar o *backpropagation* (RUMELHART *et al.*, 1986) es el




Figura 1. Ejemplo de variación del crecimiento diario del alcornoque (1=máxima contracción diaria; 2=máxima dilatación diaria; 3=crecimiento diario)

algoritmo supervisado más empleado en sistemas neuronales y su funcionamiento se basa en modificar los valores de los pesos proporcionalmente al gradiente de la función de error con objeto de alcanzar un mínimo local (algoritmo de descenso por el gradiente). Ya que la velocidad de convergencia de este algoritmo es lenta, se han propuesto pasos adicionales para acelerar esta convergencia haciendo uso de información de segundo orden de la función de error, esto es, de sus derivadas segundas o, en forma matricial, de su Hessiano, algoritmos de segundo orden como el algoritmo LM que es recomendado como primera opción a ensayar por muchos autores (TAN & VAN CAUWENBERGHE, 1999; ANCTIL & RAT, 2005).

El conjunto de datos se dividió en dos grupos: (a) el conjunto de calibración con el 75% del conjunto total de datos seleccionados al azar; y (b) el conjunto de validación externa con el 25% de los datos restantes. En este trabajo se ha utilizado un aprendizaje controlado mediante el método de la validación interna (TSOUKALAS & UHRIG, 1997; GUTIÉRREZ-ESTRADA *et al.*, 2004), es decir, que en el proceso de calibración de los modelos neuronales tras entrenar un número de épocas determinado, se recupera el conjunto de pesos que mejores resultados proporciona sobre el conjunto de validación interna (20% de los datos del conjunto de calibración seleccionados al azar y no utilizados en el ajuste de los pesos).

Se probaron RNCs con 1 y 2 capas ocultas y con 8 a 14 nodos en cada una de las capas ocultas. Se seleccionó la red neuronal con el mejor funcionamiento en el período de validación externa realizando 30 repeticiones del proceso de calibración para cada estructura de RNC ya que el conjunto de pesos inicial con el que se empieza el entrenamiento es aleatorio y, por tanto, al final del proceso no se llega a conseguir el mismo conjunto de pesos que mejores resultados proporciona.

Selección de variables de entrada a los modelos y validación externa

Para la evaluación de las variables a considerar como entrada a los modelos neuronales y de regresiones múltiples se realizaron Análisis de Componentes Principales (ACP) sobre las

variables climáticas y edáficas correspondientes a cada uno de los periodos diarios de contracción, dilatación y crecimiento de los alcornoques seleccionados. Se escogieron aquellas variables que presentaron una correlación significativa con los dos primeros factores principales superior a 0,7.

La evaluación de los modelos de RNCs y RLMs se llevó a cabo mediante el análisis de cuatro términos de error (R^2 = Coeficiente de determinación; RMSE = Error cuadrático medio; SEP = Error estándar de predicción; E = Coeficiente de eficiencia) en la regresión lineal obtenida entre valores observados (no incluidos en la fase de calibración del modelo) y estimados por los modelos. Se consideraron modelos independientes para cada árbol y modelos globales considerando los datos de crecimiento medidos para los dos árboles. Asimismo se evaluaron como variables independientes las significativas de los factores 1 y 2 de los análisis de componentes principales de forma conjunta y de forma individual.

RESULTADOS Y DISCUSIÓN

Análisis de Componentes Principales (ACP)

En la figura 2 se observa que en los tres periodos estudiados (contracción, dilatación y crecimiento) las variables climáticas precipitación y velocidad del viento no están incluidas como significativas (variables agrupadas) lo que puede indicar que su influencia en el proceso puede estar explicada en la significación de otras variables.

Validación externa de los modelos

Los resultados de validación con las aproximaciones neuronales fueron en todos los casos superiores a los obtenidos con las regresiones lineales, aportando coeficientes de correlación superiores a 0,6. La estructura óptima de las redes neuronales implica dos capas ocultas con 10 neuronas en cada una de ellas. Para los periodos diarios de contracción y dilatación los mejores resultados se consiguieron con los modelos con variables independientes las variables significativas de los factores principales 1 y 2. Para el periodo de crecimiento los mejores resultados se

Magnitudes de evaluación	Contracción		Dilatación		Crecimiento	
	RNC	RLM	RNC	RLM	RNC	RLM
R	0,951	0,852	0,907	0,784	0,809	0,737
R ²	0,904	0,725	0,823	0,615	0,654	0,543
RMSE (μm)	16,139	35,583	24,722	36,892	29,644	37,522
SEP (%)	19,481	43,619	29,279	44,015	71,692	72,115
E	0,899	0,498	0,818	0,481	0,260	0,191

Tabla 1. Comparación de las magnitudes de evaluación de los modelos de red neuronal computacional (RNC) y regresión lineal múltiple (RLM) en validación externa en las fases de contracción, dilatación y crecimiento del alcornoque A13. Las entradas a los modelos de contracción y dilatación son las variables significativas de los Factores 1 y 2 del análisis de componentes principales. Las entradas al modelo de crecimiento son las variables significativas del Factor 1 del análisis de componentes principales (R=Coefficiente de correlación lineal; R²=Coefficiente de determinación; RMSE=Error cuadrático medio; SEP=Error estándar de predicción; E=Coefficiente de eficiencia)

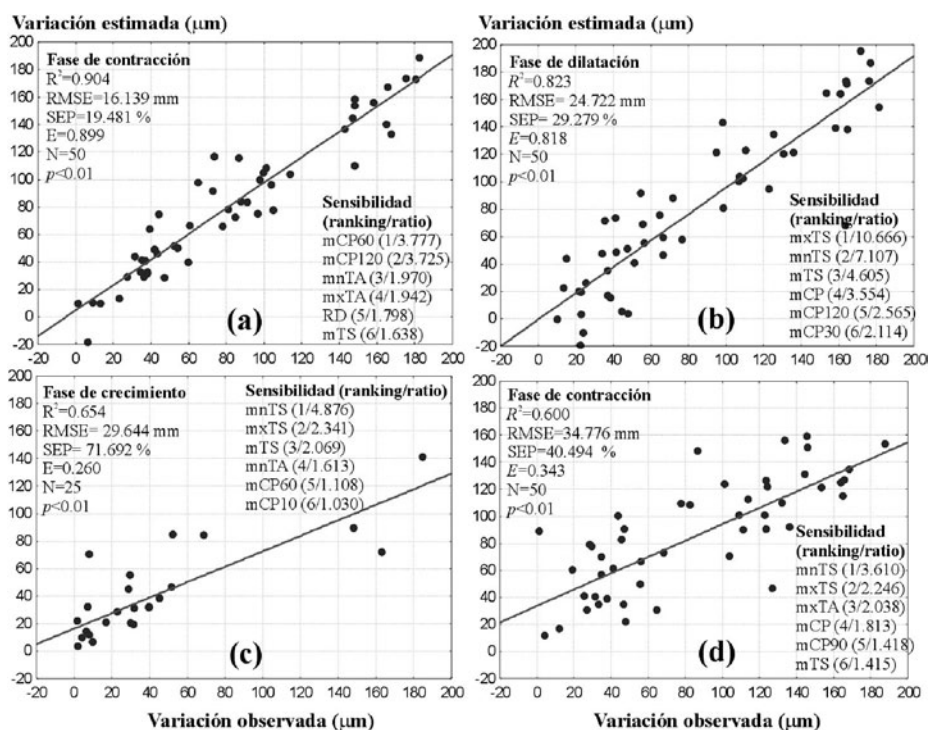


Figura 3. Validación externa de los modelos de redes neuronales en: (a) la fase de contracción del árbol A13 con entradas las variables significativas de los Factores Principales 1 y 2; (b) la fase de dilatación del árbol A13 con entradas las variables significativas de los Factores Principales 1 y 2; (c) la fase de crecimiento del árbol A13 con entradas las variables significativas del Factor Principal 1; (d) la fase de contracción de los árboles A13 y A51 con entradas las variables significativas de los Factores Principales 1 y 2

mienta útil para la estimación del crecimiento diario del alcornoque utilizando como variables de entrada o independientes parámetros edáficos y climáticos con correlación

significativa según los análisis de componentes principales realizados en los periodos diarios de contracción, dilatación y crecimiento. Las estimaciones obtenidas con los

- modelos neuronales son superiores a los obtenidos con regresiones lineales múltiples.
- Un análisis de sensibilidad analizando la influencia de las distintas variables edáficas y climáticas en los modelos de crecimiento ha mostrado que la temperatura del aire y el contenido de humedad en el suelo son los parámetros más significativos en las estimaciones desarrolladas.

Agradecimientos

Este trabajo ha sido financiado por la Unión Europea a través del proyecto del V Programa Marco “SUBERWOOD: Strategy and technology development for a cork+wood forestry chain” (QLK5-CT-2001-007001) y por el Ministerio de Educación a través del Proyecto del Plan Nacional de I+D+I “MEDCRE: “Influencia de factores ambientales en el crecimiento de especies mediterráneas (*Quercus ilex*, *Quercus suber*, *Pinus pinea*)” (AGL2005-04971). Se agradece la colaboración del Ayuntamiento de Hinojos (Huelva) y de la Consejería de Medio Ambiente de la Junta de Andalucía.

BIBLIOGRAFÍA

- ANCTIL, F. & RAT, A.; 2005. Evaluation of neural network streamflow forecasting on 47 watersheds. *J. Hydrol. Eng.* 10(1): 85-88.
- DESLAURIERS, A.; MORIN, H.; URBINATI, C. & CARRER, M.; 2003. Daily weather response of balsam fir (*Abies balsamea* (L.) Mill.) stem radius increment from dendrometer analysis in the boreal forests of Québec (Canada). *Trees* 17: 477-484.
- DOWNES, G.; BEADLE, C. & WORLEDGE, D.; 1999. Daily stem growth patterns in irrigated *Eucalyptus globulus* and *E. nitens* in relation to climate. *Trees* 14: 102-111.
- GUTIÉRREZ-ESTRADA, J.C.; DE PEDRO-SANZ, E.; LÓPEZ-LUQUE, R. & PULIDO-CALVO, I.; 2004. Comparison between traditional methods and artificial neural networks for ammonia concentration forecasting in an eel (*Anguilla anguilla* L.) intensive rearing system. *Aquacult. Eng.* 31: 183-203.
- RUMELHART, D.E.; HINTON, G.E. & WILLIAMS, R.J.; 1986. ‘Learning’ representations by backpropagation errors. *Nature* 323: 533-536.
- SHEPHERD, A.J.; 1997. *Second-order methods for neural networks*. Springer. Nueva York.
- TAN, Y. & VAN CAUWENBERGHE, A.; 1999. Neural-network-based d-step-ahead predictors for nonlinear systems with time delay. *Eng. Applic. Artif. Intell.* 12(1): 21-25.
- TSOUKALAS, L.H. & UHRIG, R.E.; 1997. *Fuzzy and neural approaches in engineering*. Wiley Interscience. Nueva York.
- VÁZQUEZ, J. Y PEREIRA, H.; 2005. Modelos de crecimiento en diámetro para alcornoques del centro y sur de Portugal. *Cuad. Soc. Esp. Cienc. For.* 18: 219-226.