



Modelización del crecimiento diametral del encinar (*Quercus ilex* subsp. *ilex*) en el Parque Natural del Montnegre y el Corredor

Iris Pilar Monfort Bague

Universidad de Lleida

Escuela Técnica Superior de Ingeniería Agraria

Departamento de Ingeniería Agroforestal

Trabajo final de Máster – Máster en Ingeniería de Montes

Dirigida por Dra. Cristina Vega Garcia

Codirigida por Dra. María de la O Sánchez González

28 de julio de 2014

Agradecimientos

A toda mi familia por el apoyo incondicional de toda una vida de educación y a mi pareja por su comprensión y ayuda en los momentos difíciles.

Agradecer a Cristina Vega y Mariola Sánchez por el auxilio y el esfuerzo brindados durante el desarrollo del trabajo.

A la Diputació de Barcelona por darme la oportunidad de trabajar en este proyecto.

A Sergi Costafreda por el apoyo dedicado en el proceso.

Y al resto de personas que han colaborado de cualquier forma en la elaboración del trabajo.

Índice

1. Introducción	1
2. Materiales y métodos	6
2.1. <u>Área de estudio</u>	6
2.1.1. Climatología	6
2.1.2. Geología	8
2.1.3. Edafología	10
2.1.4. Hidrología.....	10
2.1.5. Vegetación	11
2.2. <u>Datos</u>	13
2.2.1. Selección de parcelas.....	14
2.2.2. Toma y elaboración de datos.....	14
2.3. <u>Metodología</u>	20
2.3.1. Modelos forestales de crecimiento	20
2.3.2. Metodología de ecuaciones en diferencias algebraicas (ADA)	21
2.3.2.1. Desarrollo del modelo de crecimiento diamétrico mediante ecuaciones en diferencias algebraicas	22
2.3.3. Redes neuronales artificiales	26
2.3.3.1. Desarrollo del modelo de crecimiento diamétrico mediante redes neuronales artificiales.....	29
3. Resultados	34
3.1. <u>Estadística descriptiva de las bases de datos</u>	34
3.2. <u>Resultados de la modelización mediante ecuaciones en diferencias algebraicas</u>	36
3.3. <u>Resultados de la modelización mediante redes neuronales artificiales</u>	40
3.3.1. Modelos de diámetro – edad.....	43
3.3.2. Modelos de diámetro acumulado en función de distintas variables para la base de datos completa	44
3.3.3. Modelos de diámetro acumulado en función de distintas variables para los últimos 10 años	46

3.3.4. Modelos de incremento diametral en función de distintas variables para la base de datos completa	50
3.3.5. Modelos de incremento diametral en función de distintas variables para los últimos 10 años	51
4. Implicaciones para la gestión y discusión	53
5. Bibliografía	56

MAPA I. Localización del Parc Natural del Montnegre i el Corredor.



1. Introducción

Los bosques esclerófilos y semicaducifolios de la Península Ibérica forman parte de una ecorregión de la ecozona paleártica, dentro del bioma de bosque mediterráneo (World Wildlife Fund, 2014), considerada como una de las zonas más sensibles ante el cambio climático (EEA, 2008). Se pueden encontrar distintas especies: *Pinus pinea* L., *Quercus suber* L., *Quercus ilex* L., etc.

Las formaciones de encina de *Quercus ilex* L. se extienden por la ecorregión biogeográfica Mediterránea desde Portugal hasta Siria, y de Francia a Marruecos y Argelia, pero su presencia es mayor en el oeste de la cuenca mediterránea (Terradas y Romane, 1992), donde se desarrolla en masas densas cuando es la especie principal (Retana et al., 1996). Los encinares son la vegetación predominante en la zona de transición entre los bosques templados y los tropicales, donde las especies que habitan sobreviven bajo una alta presión por estrés hídrico y térmico, que determina sus respuestas morfológicas y ecofisiológicas (Rodà et al., 1999).

La encina es la especie climática potencial de casi la totalidad de la superficie de la Península Ibérica según el mapa de series de vegetación de España a escala 1:400.000 de Salvador Rivas-Martínez (1987), que representa la potencialidad de un territorio según criterios fitosociológicos. Debido al aprovechamiento de encina para leña y carbón de forma continua hasta el año 1960 aproximadamente y su abandono posterior, se ha producido un deterioro y degradación de estas masas (Vericat et al., 2012), dando como resultado formaciones de muy bajo porte, con mucho matorral y muy abiertas.

Los encinares se sitúan en un amplio rango de climas, con períodos muy secos y muy fríos, pero de corta duración. Su distribución está muy influenciada por la temperatura y la precipitación (Retana et al., 1996). El *Quercus ilex* L. puede vivir en prácticamente cualquier suelo, ya sea calizo rico en bases o en suelos descarbonatados sobre substrato calcáreo, y en suelos silíceos más o menos pobres en bases. No puede ocupar zonas con alta salinidad, encharcamiento prolongado y con contenidos elevados de arcillas expandibles (vertisuelos) (Diputació de Barcelona, 2014). Los encinares pueden ocupar un amplio rango de altitudes; entre el nivel del mar y 1.400

m en umbrías, o 1.900 m en solanas. Se ha apreciado que en las zonas llanas con mayor población, las encinas han ido retrocediendo y han ido ocupando las laderas con moderadas o fuertes pendientes (Vericat et al., 2012). La densidad (pies/ha) de las masas también influye en su distribución, ya que cuando se abren claros en los bosques que antes eran puros, aparecen otras especies como *Pinus pinea* L., *Prunus avium* L., *Castanea sativa* Miller, etc.

Actualmente en España, según los datos del Mapa Forestal de España (MFE50) (DGCN, 2001) la encina (*Quercus ilex* L. subsp. *ilex* y *Quercus ilex* L. subsp. *ballota*), el alcornoque (*Quercus suber* L.), el quejigo (*Quercus faginea* Lam.), el melojo (*Quercus pyrenaica* Willd.), el roble pubescente (*Quercus pubescens* Willd.) y el quejigo andaluz (*Quercus canariensis* Willd.) son especies dominantes en, aproximadamente, el 40 % de la superficie forestal española (junto con las dehesas). Esta superficie es mayor a la ocupada por coníferas (35%). Concretando más, el *Quercus ilex* L. subsp. *ballota* ocupa 4,8 millones de hectáreas, y el *Quercus ilex* L. subsp. *ilex* ocupa 3 millones de hectáreas (Vericat et al., 2012). Los encinares de ambas subespecies se encuentran actualmente en expansión (Ibáñez-Martí y Mata-Bretón, 2006). Como consecuencia del abandono del medio rural, el cese de la presión sobre los montes, y los cambios socioeconómicos introducidos por el uso de combustibles fósiles, se aprecia una recuperación de los encinares hacia un buen porte y una alta cobertura. En espacios donde los condicionantes climatológicos y topográficos son limitantes para el crecimiento, las formaciones con abundante matorral pueden perdurar mucho tiempo (Vericat et al., 2012).

Debido al abandono rural, también se desatendió la gestión selvícola intensa de los encinares. No fue tan acusada su dejadez en la parte sur y oeste de la Península Ibérica que se encaminó hacia la formación de montes adehesados, principalmente poblados por *Quercus ilex* L. *ballota*, gestión silvícola más generalizada. Las dehesas son sistemas de explotación ganadera y/o cinegética en que al menos el 50% de la superficie está ocupado por pastizal y formaciones arboladas abiertas, con fracciones de cabida de cubierta entre 5 y 60 % y con encinas o alcornoques como especies principales productoras de bellotas (Pulido y Picardo, 2010).

En la zona pre-litoral del este de España se han conservado reductos importantes de *Quercus ilex* L. subsp. *ilex* tratados como montes bajos irregulares. En Cataluña,



esta encina o *alzina* ocupa una parte muy importante de la superficie forestal, unas 150.000 ha (Vericat et al., 2012). La mayor parte de esta superficie está protegida por los Espacios Naturales de la Comunidad Autónoma, unas 80.000 ha (Ibáñez-Martí y Mata-Bretón, 2006). La estructura de estas masas se diferencia de las del resto de la Península, siendo procedentes de montes bajos irregulares, ahora montes medios irregulares debido al abandono de la gestión y aprovechamiento en los terrenos forestales. Esta gestión irregular está muy extendida en los montes catalanes, mientras que en la mayor parte de la Península Ibérica los encinares son gestionados en forma de dehesas.

La Diputación de Barcelona es responsable de la gestión de doce Espacios Naturales formados por 100.625 ha en la zona litoral y pre-litoral de la provincia de Barcelona, representando el 22 % del territorio donde vive el 70 % de la población de Cataluña. Es importante caracterizar las estructuras forestales para su correcta gestión, dada su importancia para conservar la biodiversidad y potenciar el desarrollo económico sostenible de la zona. A su vez, el objetivo principal del Parque es la multifuncionalidad del monte y su uso público, mediante itinerarios señalizados, centros de información, albergues, etc., a disposición de los visitantes, aportando un valor añadido al espacio.

Para satisfacer todas las demandas, es necesario establecer criterios silvícolas, conociendo previamente los factores y mecanismos de desarrollo de las principales variables dasométricas de los encinares. Mediante su caracterización y estudio, se puede mejorar la toma de decisiones, por ejemplo, bajo un objetivo de obtención de leñas o hacia un objetivo más recreativo del Parque, como podría ser la creación de itinerarios a través del monte siguiendo árboles monumentales escogidos en base a sus dimensiones (diámetro superior a 40 cm).

Existen algunos estudios de caracterización silvícola de *Quercus ilex* L. para montes adehesados (Vericat y Piqué, 2001). Sin embargo, hay escasa información sobre masas de monte bajo irregular de encina (Mayor y Rodà, 1993; González y Ibarz, 1998), lo cual justifica este estudio.

Con el objetivo de disponer de herramientas para la gestión de estas singulares formaciones de encinar en sus espacios, esta administración encargó un primer

estudio de las calidades de estación de la encina (en función de la altura dominante) en el Parc Natural del Montnegre i el Corredor en 2012 (Monfort, 2012).

Sin embargo, la gestión basada en diámetros en lugar de alturas presenta ventajas para los gestores, que demandan un modelo de crecimiento diamétrico, ya que el diámetro es mucho más fácil de medir por parte de los guardas del Parque. Los diámetros de las encinas son también las variables de entrada en las ecuaciones de cubicación del Inventario Forestal Nacional (Tercer Inventario Forestal Nacional, 1997 – 2007) para dicha especie. A pesar de su utilización para la obtención de leñas y carbón, nunca se ha realizado ningún estudio de modelización del crecimiento diamétrico de la encina para masas densas. En encinares adehesados, aunque tradicionalmente se han utilizado las alturas dominantes en función de la edad para la caracterización de la masa, actualmente, ya se realizan ecuaciones de diámetro dominante en función de su edad (Sánchez-González et al., 2005). Existen estudios de crecimientos diametrales para encinas en montes adehesados (Gea-Izquierdo et al., 2008) y para especies de crecimiento similar como son el *Quercus ilex* L. subsp. *ballota* en montes adehesados (Sánchez-González et al., 2009; Torres Álvarez et al., 2004) o para *Quercus suber* L. en montes no adehesados (Vázquez y Pereira, 2004).

Por otro lado, hay estudios del crecimiento diamétrico para otras especies más productivas como *Pinus occidentalis* Sw. (Bueno-López y Bevilacqua, 2013), para *Pinus radiata* D. Don (Crecente-Campo, 2008), para *Picea abies* (L.) Karst. (Øyen et al., 2012) y para *Pinus brutia* Ten. (Palahí et al., 2008).

Tradicionalmente, la planificación forestal en España se ha basado en tablas de producción, modelos estáticos aplicados a masas, no a individuos. Más recientemente se han desarrollado nuevos sistemas dinámicos de ecuaciones que permiten al silvicultor la predicción del crecimiento de las masas según varios factores. Por ejemplo los artículos de Barrio-Anta y Diéguez-Aranda (2005), de *Quercus robur* L. y el de López-Senespleda y Sánchez-Palomares (2007), del *Quercus faginea* Lam.

Los objetivos de modelizar el crecimiento en diámetro son, por una parte, describir el patrón de comportamiento diametral de la encina en masas densas, en función de factores ambientales y topográficos, estableciendo su caracterización y permitiendo la utilización de criterios técnicos a la hora de definir aspectos ácidos de su silvicultura y ordenación. Por otro lado, permite la predicción y simulación de su



crecimiento, para así, conocer las consecuencias resultantes de las diferentes modalidades de gestión futuras.

Esta caracterización también es importante para la prevención de incendios en los montes de encina, elemento perturbador de estas masas en la región Mediterránea. Debido a la proliferación del sotobosque, resultante del abandono rural, los montes se muestran mucho más vulnerables a la intensidad y tamaño del fuego. Además, el aumento continuo de las temperaturas y el aumento del período de estrés hídrico, con lluvias torrenciales más acusadas, aumentan la intensidad de los procesos erosivos en zonas con elevadas pendientes, como es el caso de varias zonas del Parque. Por estos motivos, es necesario conocer los encinares y poder gestionarlos adecuadamente (Vericat et al., 2012).

Finalmente, el objetivo del presente trabajo es modelizar el crecimiento diamétrico de un encinar en la parte Nord – Este de la Península Ibérica mediante dos metodologías diferentes, comparadas y estudiadas entre sí.

2. Materiales y métodos

2.1. Área de estudio

La zona de estudio se centra en el Parc Natural del Montnegre i el Corredor, provincia de Barcelona, en la Cordillera Litoral Catalana, entre las comarcas del Maresme y el Vallés Oriental, con una extensión aproximada de 15.010 ha. Está formado por 6.255 ha de superficie no forestal y 8.755 ha de superficie forestal (Mapa I).

La mayor parte del Parque es propiedad privada (90,75%) y el resto, de propiedad pública (9,25%), gestionado todo por el Servicio de Parques Naturales de la Diputación de Barcelona con la colaboración de los Ayuntamientos, que aseguran la preservación de los valores naturales y culturales, el uso público ordenado de la montaña, las demandas culturales, pedagógicas y científicas y el desarrollo socioeconómico de la zona.

2.1.1. Climatología

En cuanto al clima, se distinguen dos zonas; las tierras interiores orientadas hacia el norte, más frías y húmedas, y las tierras litorales orientadas hacia el sur, más secas y con temperaturas más elevadas.

En la figura 1 se representa la temperatura media anual con la precipitación acumulada anual entre los años 1925 y 2011, que coinciden con la edad máxima del árbol más maduro estudiado. En la figura 2 se establece la misma relación pero para los últimos 10 años, debido a la limitación, posteriormente explicada, de datos de rodal para cada año de vida de la masa. Y en la figura 3 se dibuja el diagrama ombrotérmico que se obtiene a partir de los datos climatológicos cedidos por la Diputación de Barcelona para los años 2001 a 2011.

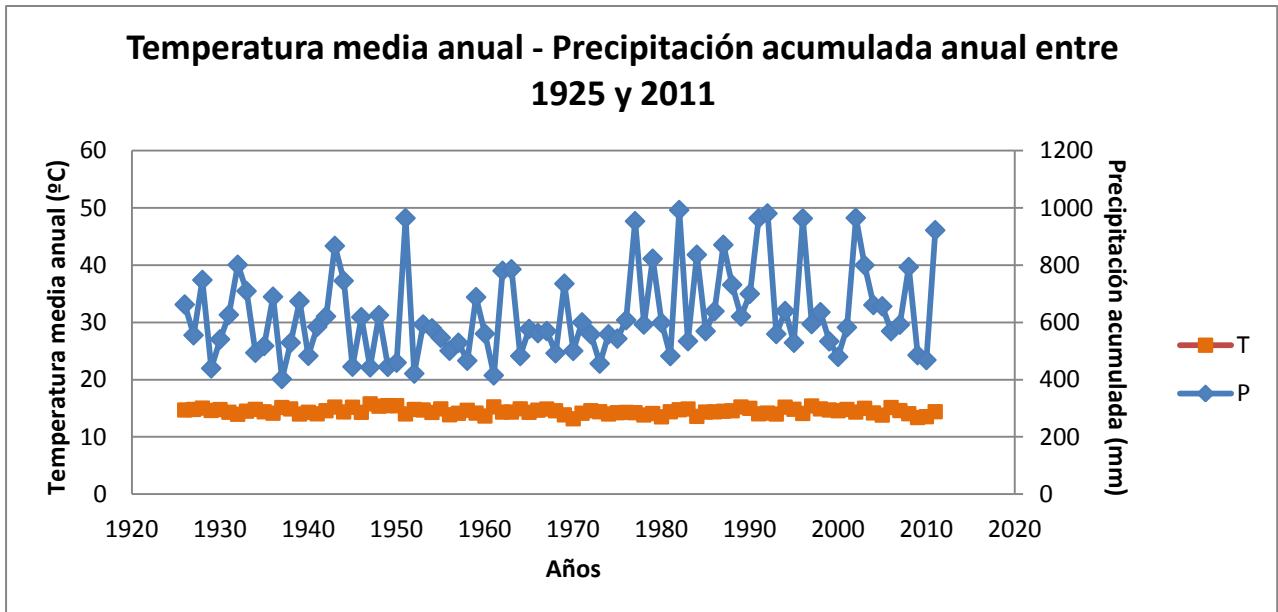


Figura 1. Representación de la temperatura media anual y la precipitación acumulada anual entre los años 1925 y 2011.

Analizando el gráfico anterior, el rango de precipitaciones es muy variable, en cambio el de temperatura, no cambia demasiado de un año a otro.




Figura 2. Representación de la temperatura media anual y la precipitación acumulada anual entre los años 2001 y 2011.

En la figura 2 se representan las temperaturas medias anuales y la precipitación acumulada anual, apreciándose que entre los años 2003 y 2008 hubo escasa

precipitación, a la vez que entre los años 2009 y 2010; pero, la temperatura anual media se mantuvo constante.




Figura 3. Diagrama ombrotérmico de la estación meteorológica de Collsacreu en el Montnegre y Corredor entre el período de 2001 y 2011.

Se observa un amplio rango interanual de precipitaciones concentradas en aguaceros que provocan avenidas en las cuencas del Maresme entre los años 2001 y 2011, con un claro período de estrés hídrico entre los meses de verano (junio a agosto).

2.1.2. Geología

Los macizos del Montnegre y el Corredor definen parte de la Cordillera Litoral Catalana y están formados básicamente por un gran cuerpo granítico atravesado por rocas filonianas.

En la parte del Montnegre el material metamórfico es más resistente a la erosión. Por el contrario, en el Corredor, hay mayor roca granítica que, a causa de la humedad ambiental y las elevadas temperaturas, se disgrega con relativa facilidad,



formando el típico saulón de la zona, dándole una forma más suave a esa parte de la Cordillera (Diputació de Barcelona, 2014).

Las montañas están formadas básicamente por granitoides alterados, con fajas de la era carbonífera y ordoviciana, intercaladas con materiales más o menos carbonatados del devoniano y del siluriano. Se aprecian afloraciones de pizarras provenientes de sedimentos finos y argilosos que se metamorfosearon. Lo mismo ocurrió con las afloraciones de rocas calcáreas.

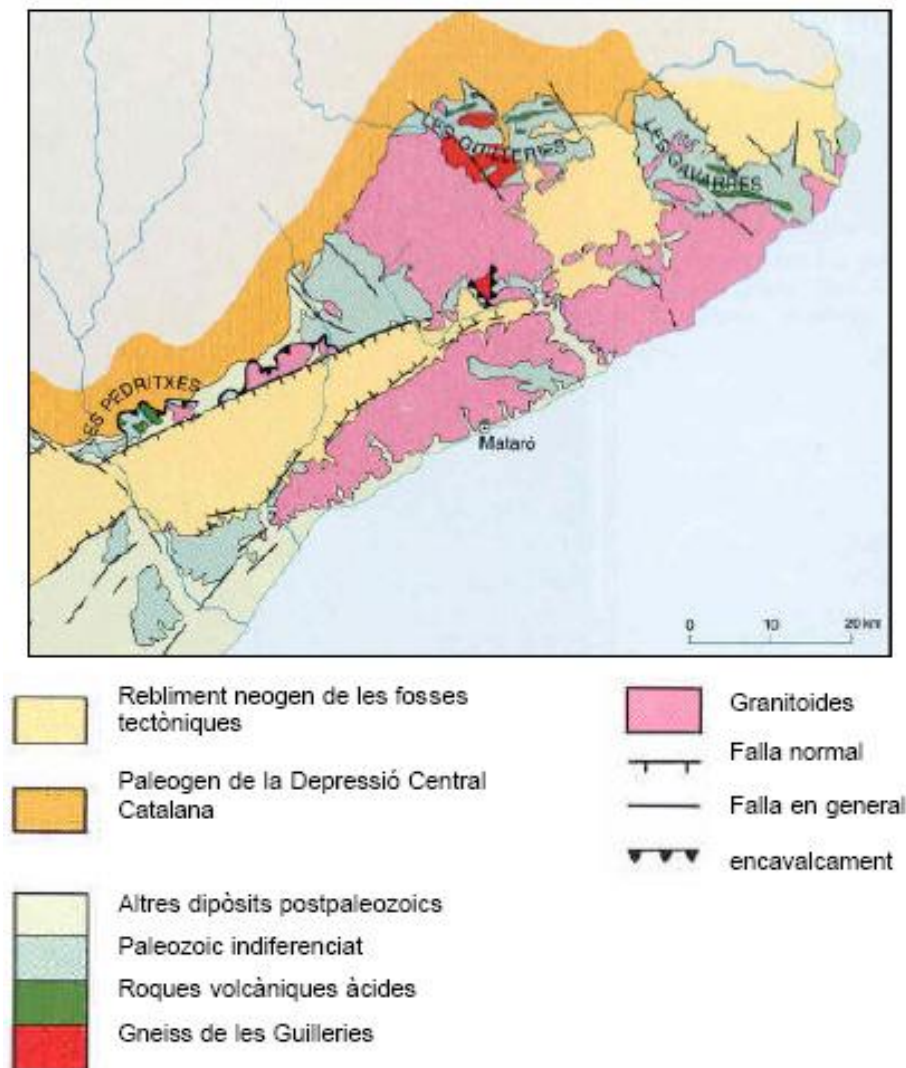


Figura 4. Geología del Parque (Diputació de Barcelona, 2014).

2.1.3. Edafología

Los suelos característicos del Parque son suelos silíceos formados sobre materiales graníticos, metasedimentarios y detríticos cuaternarios. Tienen una textura moderadamente gruesa, proporcionándole una baja capacidad de retención de agua de drenaje (Diputación de Barcelona, 2014).

Se clasifican los suelos como entisoles, inceptisoles y alfisoles (Soil Survey Staff, 2014). La temperatura es de régimen térmico en las zonas más cercanas al litoral y régimen méxico en las partes más altas. El régimen de humedad es xérico.

2.1.4. Hidrología

En el Parque se localizan pequeñas cuencas de gran pendiente y de recorrido corto, con materiales poco permeables en las zonas de cabecera y permeables en la parte baja, por donde el agua fluye. Por este motivo, cuando se producen los aguaceros irregulares típicos de esa zona, se desarrollan grandes avenidas de agua.

Se diferencian dos cuencas principales, la del Tordera formada por los torrentes que van del área del Montnegre hacia el río Tordera, y la cuenca del Maresme, donde los cursos de agua son perpendiculares al mar y tiene torrentes cortos que evacuan el agua del área del Montnegre y el Corredor.

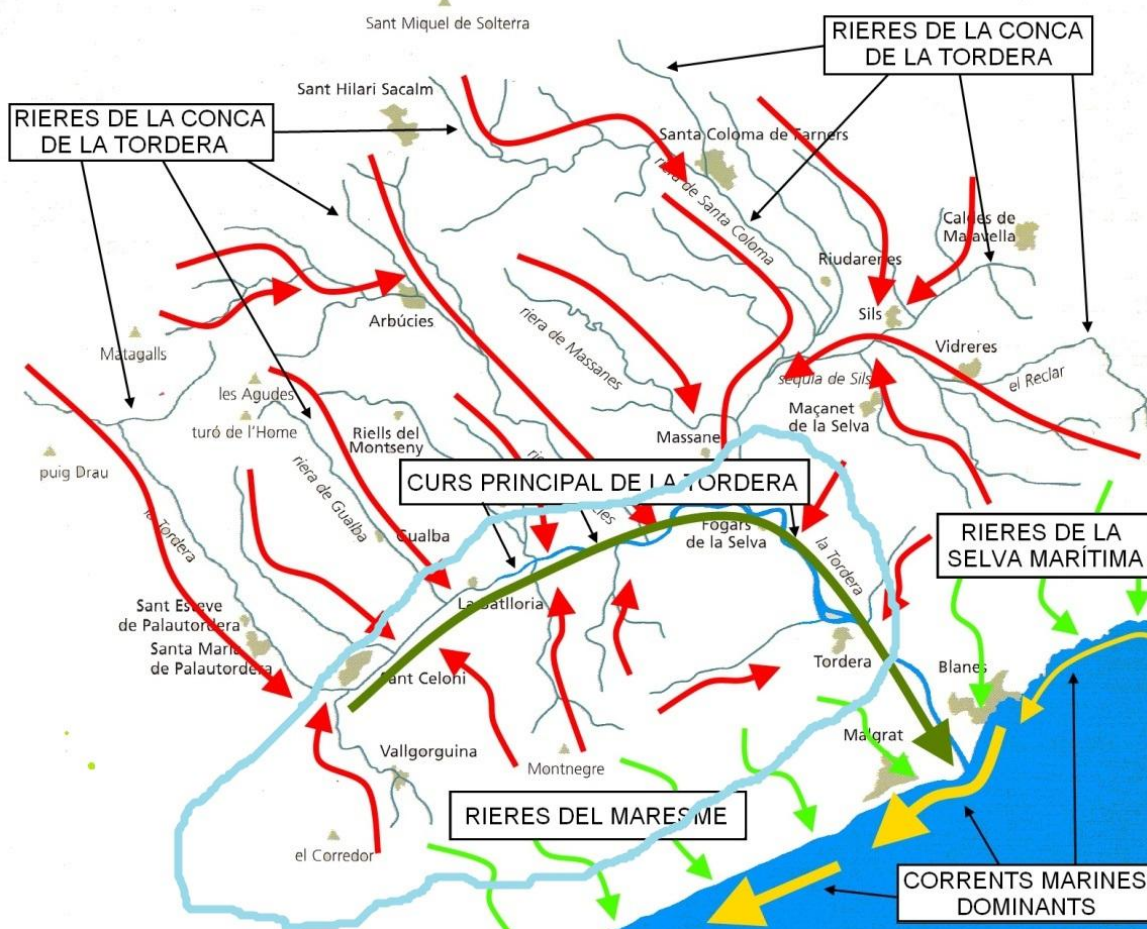


Figura 5. Cuenca hidrogràfica del Tordera (Orchis Naturalistes, 2014)

2.1.5. Vegetación

El Parque se caracteriza por la presencia predominante de bosques esclerófilos de encinas (*Quercus ilex* L.) y alcornoques (*Quercus suber* L.) con presencia de árboles caducifolios de carácter submediterráneo. Aunque el bosque potencial es el encinar, se ha ido substituyendo en muchas ocasiones por pinares, matorral, prados o campos agrícolas. En las zonas con mayor humedad o cercanas a los cursos fluviales se establece la vegetación de ribera con *Fraxinus excelsior* L., *Salix babylonica* L. y *Populus tremula* L. En estos espacios también aparecen herbazales altos, zarzas y matorral.

Es necesario mencionar que se repoblaron algunas superficies del Parque con pino piñonero (*Pinus pinea* L.) para la producción de piñones, pino resinero (*Pinus pinaster* Ait.) utilizado para madera y producción de resina, pino insigne (*Pinus radiata*

D. Don) para el aprovechamiento de madera y, finalmente, eucaliptos (*Eucalyptus globulus* Labill.).

Dentro del límite del Parque, se pueden establecer distintos estratos de vegetación según la topografía, el suelo, el clima y el aprovechamiento de madera (Diputación de Barcelona, 2014):

✚ Encina con *Viburnum tinus* L. o encinar típico: predomina en las laderas inferiores de la montaña y en los lugares más secos y soleados de las partes superiores. Soporta estrés hídrico durante el verano, con poco suelo disponible y una baja capacidad de retención de agua. La encina se puede encontrar en asociación con *Pistacia lentiscus* L., *Arbutus unedo* L., *Asplenium adiantum* L., *Hedera hélix* L. y robles, en lugares donde la humedad sea superior, debido a la proximidad del mar.

✚ Encinar montañés: habita las laderas más superiores, con temperaturas más bajas y humedades altas, pero no lo suficiente para establecerse una formación de roble.

✚ Otras masas mixtas con *Pinus pinea* L., *Populus tremula* L., *Corylus avellana* L., *Prunus avium* L., *Castanea sativa* Miller, también se encuentran presentes.

El *Quercus ilex* L. subsp. *ilex* es una especie que forma parte de las Gimnospermas, de la familia de las Fagaceas. La parte superior de las hojas es de un verde oscuro y la parte inferior está cubierta de pequeños tricomas blancos (Rodà et al., 1999). Es tolerante a la sombra y, como consecuencia, se convierte en especie dominante en las etapas finales de sucesión. Es un árbol perenne que puede llegar a los 27 metros de altura y de crecimiento lento, formando densas masas. Su madera es densa, cosa que dificulta el reconocimiento de los verdaderos anillos de crecimiento.

Este estudio se centra en las zonas del Parque con presencia mayoritaria de la encina, representativa de las formaciones de encinares del este de la Península Ibérica y zonas mediterráneas de Francia, Italia y Grecia que se han gestionado tradicionalmente a través de un modelo silvícola de monte bajo irregular mediante cortas de entresaca, con el objetivo principal de obtener leñas y disminuir el riesgo de incendios. Éste tipo de modelo mantiene una estructura irregular pie a pie, dejando



tres o más generaciones de pies, promoviendo los árboles con buen porte, con una fracción de cabida de cubierta equilibrada, con vitalidad y una buena capacidad de respuesta frente a estrés hídrico.

2.2. Datos

Algunos de los datos utilizados para modelizar el crecimiento diametral de la encina proceden de una toma de datos anterior. Se tomaron para el trabajo práctico tutorado de determinación de las curvas de calidad de la estación para el Parque. En él se trató de modelizar las calidades de estación en función de la altura dominante de los árboles en distintos rodales.

Posteriormente, la Diputación de Barcelona solicitó un proyecto para la caracterización de la masa forestal de encinas existentes mediante diámetros, con el objetivo de gestionar estos montes para un posterior aprovechamiento forestal y/o lúdico-recreativo.

Para ello se requerían datos de:

- ✚ Masa o rodal: área basimétrica (m^2/ha) y densidad (pies/ha). Para conseguir introducir estas variables en los modelos, se tuvieron que considerar sólo los últimos 10 años, debido a que solamente se disponía de los datos tomados el año que se cortaron los árboles (Pretzch, 2010).
- ✚ Árbol individual: incremento diametral anual (mm/año), diámetro acumulado anual (cm) y edad (años).
- ✚ Topografía: altitud (m) y pendiente (%).

Se analizaron los datos de 48 parcelas de 10 metros de radio donde la especie dominante era la encina, y donde no se había producido ninguna perturbación en la masa en los últimos 10 años.

2.2.1. Selección de parcelas

Las parcelas de estudio eran temporales, y se seleccionaron en base a distintos criterios:

- ✚ El rodal debía presentar encina como especie principal.
- ✚ Rodal con una superficie mínima de 10 m de radio, y sus límites debían estar lejos de cualquier elemento del terreno que pudiera causar efecto límite (como pistas, líneas eléctricas, etc.) (Pardé y Bouchon, 1994).
- ✚ Inexistencia de actuaciones silvícolas o daños importantes por incendios u otras perturbaciones en los últimos 10 años.
- ✚ Pequeñas masas o rodales homogéneos en edad y altura.
- ✚ Pies repartidos uniformemente.
- ✚ Parcelas de distintas calidades y densidades.

Las parcelas inventariadas finales tenían unas pendientes entre el 12 y el 100 % y unas altitudes entre 200 y 725 m respecto al nivel del mar.

2.2.2. Toma y elaboración de datos

En las parcelas a inventariar se escogió un árbol tipo en cada una. Este árbol se tronizó a ras de suelo y luego a 1.30 m se cortó una rodaja para llevarla al laboratorio. A cada rodaja se le marcó el número de la parcela.

Las siguientes figuras permiten apreciar visualmente las características silvícolas de algunas de las parcelas.



Figura 6. Vista de la parcela 93



Figura 7. Vista de la parcela 42

Las muestras se llevaron al laboratorio del Instituto Nacional de Investigaciones Agrarias y Alimentarias de Madrid (INIA), se midieron las edades mediante el conteo de anillos en la base de la rodaja a 1.30 m, teniendo en cuenta que esas edades, son edades relativas. Esto es debido a que no se sumaron los años que la encina tardó en llegar a 1.30 m, y que, por lo tanto, todos los modelos se realizaron en base a las edades relativas. Para tener edades absolutas, es necesario conocer cuántos años tarda la encina en llegar a la altura de 1.30 m, mediante un muestreo anual de su crecimiento, desde que nace hasta la altura deseada.

Para contar los anillos de crecimiento, se siguió la metodología de Gené et al. (1993), debido a su dificultad. El crecimiento vegetativo de la encina sucede entre mayo y junio en las masas orientadas hacia el norte, y con un mes de antelación en tierras bajas. A veces, puede existir un segundo crecimiento a finales del verano o principios de otoño, que produce falsos anillos difíciles de diferenciar (Rodà et al., 1999), además de tener un crecimiento lento, con incrementos diametrales muy pequeños. Habitualmente, para contar los anillos de crecimiento de un árbol, se siguen las bandas correspondientes a las células procedentes de la madera tardía, más gruesas que las de madera temprana, que puede confundir al medidor. En el caso de la

encina, estas bandas no pueden seguirse ya que es muy difícil de distinguir, con el factor en contra añadido de que hay falsos anillos difíciles de interpretar. Una forma de evitar esto, es el análisis del patrón seguido por los vasos conductores en ese anillo. El *Quercus ilex* L. es una madera semiporosa, en la que los vasos se encuentran longitudinalmente en todo el anillo, sin seguir un patrón igual, pero el diámetro de estos va disminuyendo a medida que se acerca al final del periodo de crecimiento. Este es uno de los principales factores que provocan el desconocimiento del crecimiento de la encina.

Para mejorar la observación de las muestras, se pulieron con una pulidora de banda con papel de lija de diferente grano, actuando en sentido longitudinal sobre éstas, y con otra de tipo orbital, que va en sentido circular sobre la muestra, permitiendo un tipo de papel de lija mucho más fino. Además, para eliminar los residuos que taponaban los vasos, se aplicó aire a presión.

Finalmente, se obtuvo una rodaja como la presentada en la figura 8, vista en el microscopio, con las marcas de los anillos después de pasarla por las pulidoras.






Figura 8. Imagen de una rodaja en la estación de medida TSAP.

A continuación se determinó el crecimiento anual (ancho) de cada anillo contado en la dirección del radio medio de la sección de la rodaja con la ayuda de una estación de medida de los anillos de los árboles (LINTAB) que se encuentra en el Instituto Nacional de Investigaciones Agrarias y Alimentarias de Madrid (INIA). Los datos obtenidos en la estación se procesaron con la herramienta de software TSAP (1996).

En la figura 9 se ve el microscopio donde está instalado el LINTAB (herramienta horizontal debajo del observatorio del microscopio) para medir la distancia entre anillos de crecimiento. Y en la figura 10 se representa el incremento radial de la rodaja en la pantalla de trabajo de la herramienta TSAP (1996). Con esta herramienta informática, lo que se obtienen son los incrementos de radio, es decir, lo que tarda el árbol en crecer un año. Para conocer los diámetros se tienen que multiplicar por dos los incrementos radiales, generando los denominados incrementos diametrales a lo largo del documento.




Figura 9. Microscopio con la herramienta TSAP instalada.

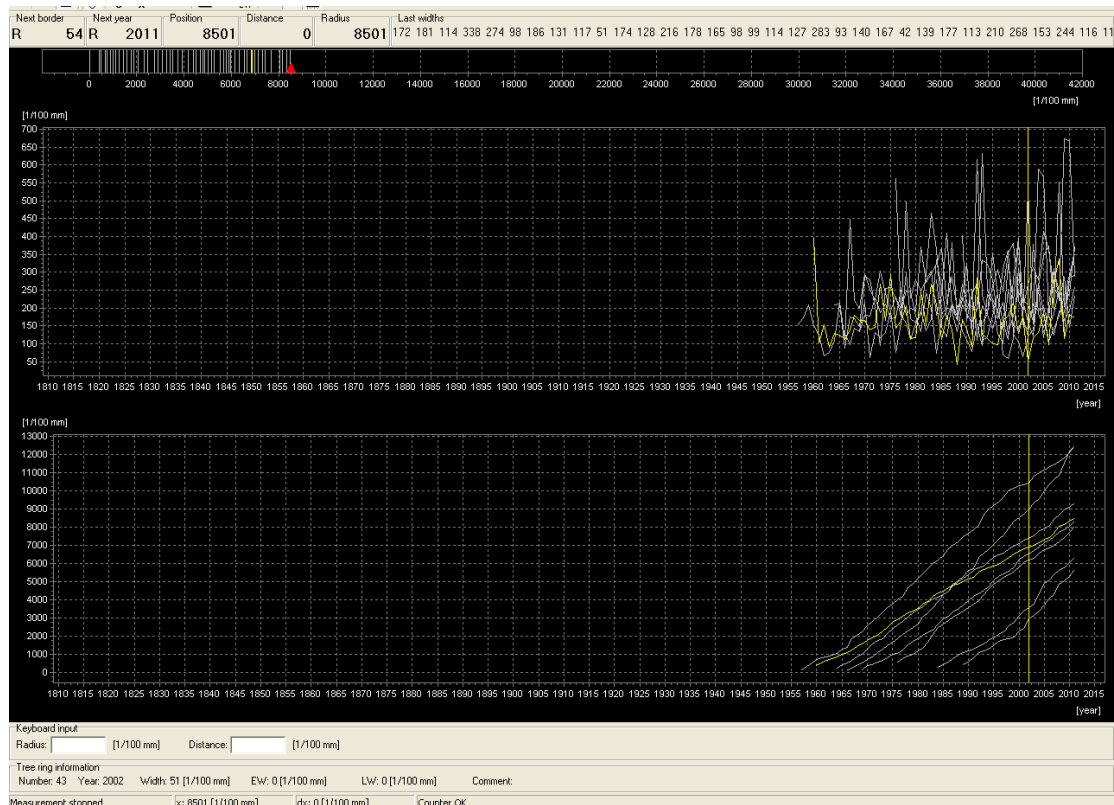


Figura 10. Pantalla ordenador de la herramienta de software TSAP.

Una vez procesados los datos de los incrementos radiales o diametrales, se confeccionaron cuatro bases de datos distintas:

- ✚ Diámetros acumulados para las edades completas.
- ✚ Diámetros acumulados para los últimos 10 años de cada árbol.
- ✚ Incrementos diametrales para las edades completas.
- ✚ Incrementos diametrales para los últimos 10 años de cada árbol.

Las bases de datos parciales, estaban comprendidas por los diámetros e incrementos diametrales de los 10 años últimos antes de la corta, ya que, al no tener datos de densidad y área basimétrica anteriores a la medición, según Pretzch (2010), si no se producía ninguna perturbación entre 5 o 10 años, para especies de crecimiento lento, estas variables se mantienen constantes. Al poder optar a más factores para explicar el crecimiento, se dividieron los datos en las bases anteriores.

Los datos obtenidos y procesados mediante el TSAP (1996) se presentan en la figura 11.

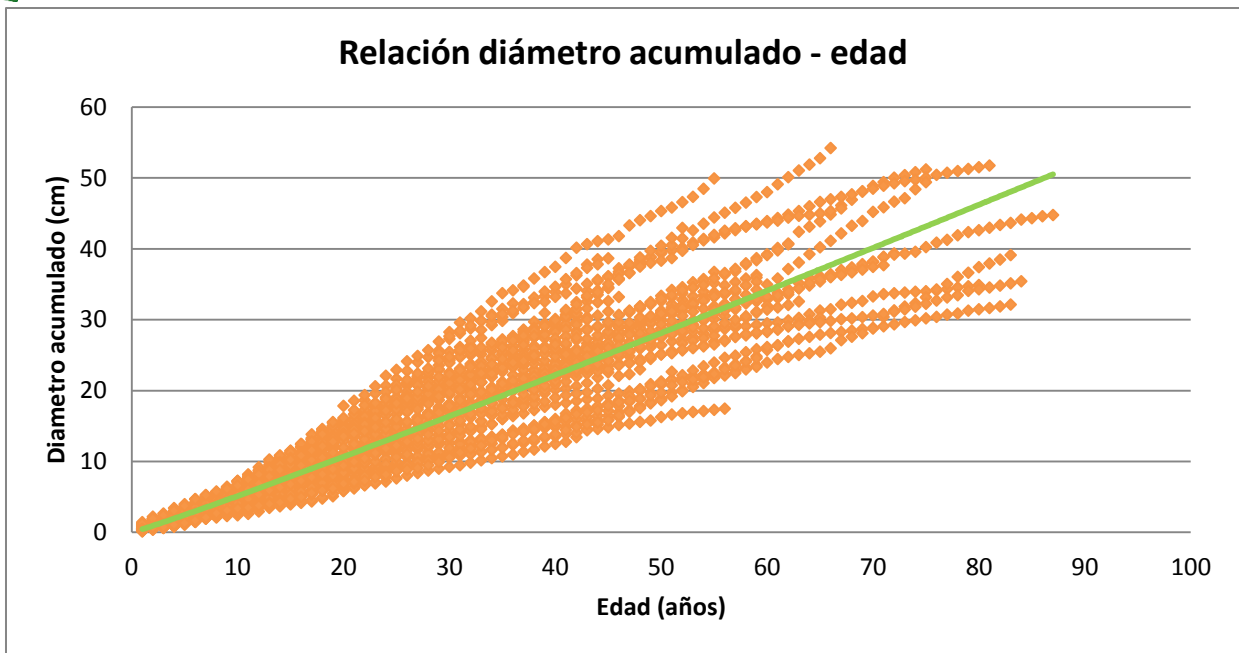


Figura 11. Relación diámetro acumulado – edad para las 48 parcelas estudiadas.

Y, en la figura 12, se representan los datos obtenidos para los últimos 10 años, procedentes de la base de datos parcial.




Figura 12. Relación diámetro acumulado – edad para las 48 parcelas estudiadas en los últimos 10 años.

2.3. Metodología

Los modelos de crecimiento diamétrico se realizan mediante diferentes metodologías y herramientas estadísticas. Para este proyecto, se desarrollan y comparan los ajustes estadísticos tradicionales mediante el software R (R Core Team, 2014) con otras herramientas estadísticas de predicción más actuales, como son las Redes Neuronales Artificiales, mediante uno de sus algoritmos de correlación en cascada (NeuralWare, 2009). A su vez, también se compararon los modelos hechos en base al diámetro y los elaborados, para las mismas parcelas, con alturas dominantes (Monfort, 2012).

2.3.1. Modelos forestales de crecimiento

Un modelo es una representación simplificada de algún aspecto de la realidad. Un modelo de crecimiento es un sistema de ecuaciones que predicen el crecimiento de un monte, bajo distintas condiciones climáticas y/o edáficas, imitando el crecimiento real de los árboles (Vanclay, 1994). Pueden clasificarse de muchas maneras, entre ellas, cuatro son las más frecuentes: según la unidad de predicción, según sean modelos estáticos (tablas de producción) o dinámicos (en función de variables de rodal o de árbol), según sean modelos determinísticos o estocásticos y según sean o no modelos empíricos (Diéguez-Aranda et al., 2009; Bravo et al., 2000).

El crecimiento y la producción pueden estimarse mediante (Barrio-Anta et al., 2012):

✚ **Curvas de Índice de Sitio (*Site Index*):** son el tipo de modelos más utilizados para la estimación de la productividad (Barrio-Anta et al., 2012; Elfving y Kiviste, 1997). Aunque son de los métodos utilizados con mayor frecuencia, para los gestores del Parque les resulta más útil un modelo diamétrico.

- Método de la curva guía (Clutter et al., 1983)
- Método de predicción de parámetros (Clutter et al., 1983)



- Método de ecuaciones diferenciales algebraicas, ADA, (Bailey y Clutter, 1974) y su generalización, GADA, (Cieszewski y Bailey, 2000). A partir de datos obtenidos del análisis del árbol, éste es uno de los métodos más fiable y utilizado en la mayoría de casos.
- ✚ **Ecuaciones de crecimiento en diámetro y área basimétrica:** predice el crecimiento del área basimétrica y el diámetro basándose en los distintos factores ambientales y topográficos (Sánchez-González et al., 2005).
- ✚ **Funciones de altura** mediante (Amaro et al., 1998):
 - La altura de todos los árboles de un rodal.
 - Clasificación diamétrica en relación a la altura futura de los árboles del rodal (López-Sánchez et al., 2012; López-Sánchez et al., 2002).
 - Toma de datos entre dos tiempos distintos de la altura de los árboles para estimarla en un futuro.
- ✚ **Funciones de crecimiento del volumen** (Condés et al., 2012).

2.3.2. Metodología de ecuaciones en diferencias algebraicas (ADA)

El método de ecuaciones en diferencias algebraicas, ADA (*algebraic difference approach*) es una técnica para derivar ecuaciones dinámicas. Este procedimiento permite la substitución de un parámetro del modelo base (Bailey y Clutter, 1974) y expresarlo como una combinación de diámetro dominante – edad.

Los modelos ADA se expresan de la siguiente forma (Bailey y Clutter, 1974):

$$d_2 = f(d_1, t_1, t_2)$$

Donde:

- d_1 : diámetro acumulado en el t_1 o diámetro observado.
- d_2 : diámetro acumulado en el t_2 o diámetro predicho.
- t_1 : edad del árbol para d_1 .
- t_2 : edad del árbol para d_2 .

Las ventajas de los ADA son (Cieszewski y Bella, 1989; Clutter et al., 1983):

- ✚ Puede utilizarse para observaciones temporales cortas (parcelas temporales).
- ✚ La edad de referencia es invariante. Esto significa que para cualquier punto (d_1, t_1) permite predecir diámetros a una edad determinada.

Mediante este proceso se modeliza el crecimiento de una variable con una familia de curvas con todos los parámetros iguales. Solamente uno es diferente, la calidad de estación forestal. Se pueden originar curvas anamórficas (mismo patrón de crecimiento pero distinta asíntota) o polimórficas (no son proporcionales las unas con las otras). Su limitación es que la familia de curvas que se producen suelen ser anamórficas (Diéguez-Aranda et al., 2009).

2.3.2.1. Desarrollo del modelo de crecimiento diamétrico mediante ecuaciones en diferencias algebraicas

Se ensayaron 4 ecuaciones que se presentan en la Tabla 1. Estas fueron seleccionadas a partir de 2 artículos de investigación forestal, por ser artículos actuales con ecuaciones ADA utilizadas frecuentemente en la modelización: López-Senespleda y Sánchez-Palomares (2007) y Barrio-Anta y Diéguez-Aranda (2005).



Tabla 1. Funciones seleccionadas para el ajuste.

Ecuación base	Parámetro libre	Ecuaciones en diferencias algebraicas (ADA)	Código modelo	Artículo extraído
McDill-Amateis (1992) $d = \frac{a}{1 + \frac{b}{t^c}}$	b	$d_2 = \frac{a}{1 - \left(1 - \frac{a}{d_1}\right) \cdot \left(\frac{t_1}{t_2}\right)^c}$	MA	(López-Senespleda y Sánchez-Palomares, 2007)
Bailey & Clutter (1974) $d = e^{a+b \cdot t^c}$	b	$d_2 = e^{a+(Lnd_1-a) \cdot \left(\frac{t_2}{t_1}\right)^c}$	BC	(López-Senespleda y Sánchez-Palomares, 2007)
Hossfeld I (citado en Preschel, 1938) $d = \frac{t^2}{a + b \cdot t + c \cdot t^2}$	b	$d_2 = \frac{t_2^2}{a + t_2 \cdot \left(\frac{t_1}{d_1} - \frac{a}{t_1} + c \cdot (t_2 - t_1)\right)}$	HOSS	(Barrio-Anta y Diéguez-Aranda, 2005)
Korf (citado en Lundqvist 1957) $d = a \cdot e^{(-b \cdot t^{-c})}$	b	$d_2 = a \cdot \left(\frac{d_1}{a}\right)^{\left(\frac{t_1}{t_2}\right)^c}$	KO	(Barrio-Anta y Diéguez-Aranda, 2005)

Conocidas las ecuaciones dinámicas, se introdujeron en el estadístico R (R Core Team, 2014), para estimar los parámetros y obtener los estadísticos necesarios para la selección del mejor modelo.

Los paquetes estadísticos utilizados fueron:

- ✚ plotrix: útil para realizar gráficos (Lemon, 2006)
- ✚ gvlma (validación global de modelos lineales supuestos): consiste en realizar una prueba global para evaluar los supuestos del modelo lineal, así como realizar pruebas específicas para detectar asimetría, curtosis y heterocedasticidad (Pena y Slate, 2006).
- ✚ nlme: ajusta y compara modelos lineales y modelos de efecto mixto no lineales (Pinheiro et al., 2014).
- ✚ nls2: consiste en determinar los mínimos cuadrados no lineales estimados de los parámetros del modelo no lineal (Grothendieck, 2013).
- ✚ lmfor: contiene una colección de funciones para diferentes propósitos relacionados con la biometría forestal (Mehtdtalo, 2008).

Para elegir el mejor modelo, los estadísticos de bondad de ajuste más comunes son:

- ✚ **Error residual estándar (RSE):** es el error que se comete al predecir la variable Y en función de la variable X. Por lo tanto, cuanto menor sea el RSE, mejor.

$$\sigma = \sqrt{\frac{SSE}{n - p}}$$

Donde:

- SSE es la suma de los errores al cuadrado.

$$SSE = \sum_{i=1}^{i=n} (Y_i - \hat{Y}_i)^2$$

- n: número total de observaciones utilizado para ajustar el modelo.
- P: número de parámetros a estimar.
- Y: valores observados de la variable dependiente.
- \bar{Y} : peso de los valores observados.

- ✚ **Error medio absoluto:** es el error medio entre los valores observados y predichos, en sus mismas unidades.

$$\frac{\sum_{i=1}^n |Y_{predicho} - Y|}{n}$$

Donde:

- Y: valores observados de la variable dependiente.
- $Y_{predicho}$: valores de la variable dependiente predichos mediante la ecuación lineal.
- n: número total de observaciones utilizado para ajustar el modelo.

- ✚ **Raíz del error cuadrático medio (RMSE):** proporciona la desviación estándar del error predicho por el modelo. Se expresa en las mismas unidades que la variable predicha (Crecente-Campo, 2008).



$$\sqrt{\frac{\sum_{i=1}^{i=n} (Y_i - \hat{Y}_i)^2}{n - p}}$$

Donde:

- n: número total de observaciones utilizado para ajustar el modelo.
- P: número de parámetros a estimar.
- Y: valores observados de la variable dependiente.
- \bar{Y} : peso de los valores observados.

✚ **Criterio de información de AKAIKE (AIC)** (Akaike, 1974): medida relativa de la bondad del ajuste del modelo, para un rango de datos dado. Cuánto más pequeño sea, mejor modelo es. Este criterio, sanciona a los modelos con un mayor número de parámetros (Peña, 2002), en base al principio de simplicidad.

$$AIC = n \times \log(\sigma^2) + 2 \times k$$

Donde:

- $K = p + 1$
- $\sigma = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}$ Estimador de la varianza.
- n: número total de observaciones utilizado para ajustar el modelo.
- Y: valores observados de la variable dependiente.
- \bar{Y} : peso de los valores observados.

✚ **Criterio de información Bayesiano (BIC o Bayesian information criterion):** parámetro muy relacionado con el criterio de AKAIKE y la función de probabilidad (Schwarz, 1978).

$$BIC = n \times \log(\sigma^2) + k \times \ln(n)$$

Donde:

- $K = p + 1$
- $\sigma = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}$ Estimador de la varianza.
- n: número total de observaciones utilizado para ajustar el modelo.
- Y: valores observados de la variable dependiente.
- \bar{Y} : peso de los valores observados.

2.3.3. Redes neuronales artificiales

Una red neuronal artificial es un sistema de procesamiento de datos que simula una estructura neuronal biológica modelizando esquemáticamente la configuración funcional de un cerebro formado por neuronas, nodos y elementos de procesamiento interconectados y organizados en capas (Faucett, 1994). La forma más sencilla de desarrollar estas redes neuronales es mediante un software específico en un ordenador (Hilera y Martínez, 1995).

Las ventajas de las redes neuronales son (NeuralWare, 2009):

- ✚ No requieren asumir una determinada distribución en los datos iniciales.
- ✚ Permiten efectos de correlación entre variables.
- ✚ Predicen modelos no lineales.
- ✚ Pueden ser más robustas y predecir mejor que los modelos estadísticos tradicionales.

En general, las redes neuronales artificiales se inician en un procesador elemental llamado neurona, entendida como dispositivo de cálculo simple que parte de un vector de entrada y que se combina para obtener un vector de salida. Se organizan en varias capas formando una red neuronal artificial con funcionalidad propia. Con una o más redes neuronales, las interfaces de entrada y salida y otros, constituyen el sistema global o “sistema nervioso” (NeuralWare, 2009).

La red neuronal artificial está formada por un conjunto de neuronas y sus conexiones:

✚ Neuronas conectadas entre sí (Faucett 1994). Generalmente se pueden encontrar 3 tipos de neuronas:

- Capas o unidades de entrada (X) que introduce los datos a la red neuronal.
- Capas o unidades ocultas (B) donde se procesan los datos y se ponderan los pesos de cada variable.



- Capas o unidades de salida (Y) que representa la respuesta de la red neuronal a los datos de entrada.
- ✚ Estructura de conexiones similares a las conexiones sinápticas de los sistemas neuronales biológicos: cada conexión tiene un peso específico que modifica la magnitud de la señal de transmisión obteniendo un resultado positivo o negativo. El proceso de modificación de las conexiones se le llama *aprendizaje*. Para modificar estos pesos se utiliza el error estimado entre los valores predichos y los observados, mientras los pesos van variando hasta converger (Alcázar et al., 2008). Los pesos de cada variable proporcionan la *función de activación* o *transformación* de la red, ya sea una función lineal, sigmoideal, lineal a tramos o escalón, entre otras funciones menos utilizadas. Una vez que los pesos se mantienen estables, se entiende que la red ya ha acabado de *aprender*, y se dice que la red *converge* (Hilera y Martínez, 1995).

El aprendizaje puede ser:

- ✚ **Aprendizaje supervisado:** consiste en un entrenamiento dirigido por un elemento externo que controla los datos de salida, de forma que, si no coinciden con los datos deseados, altera los pesos de las variables para aproximarse lo máximo posible a ellos (Hilera y Martínez, 1995).

Hay tres formas de desarrollarlo:

- Aprendizaje por corrección de error: se basa en ajustar los pesos de las variables según los errores cometidos en la salida (valores observados menos valores predichos). Es un ejemplo la *correlación en cascada*.
- Aprendizaje por refuerzo: se basa en mecanismos probabilísticos.
- Aprendizaje estocástico: según las distribuciones de probabilidad y los valores observados, se efectúan variaciones aleatorias en los pesos de las variables.
- ✚ **Aprendizaje no supervisado:** a diferencia del anterior, éste no necesita un agente externo para el ajuste de los pesos.

Para realizar el proceso de aprendizaje supervisado se necesitan datos de *entrenamiento* iniciales para que el ajuste de los parámetros dé los resultados reales

(Hilera y Martínez, 1995). El número de datos disponibles para desarrollar los modelos, es muy importante, principalmente para la fase de *aprendizaje*. Para resolver problemas con el número de datos, se puede limitar la estructura de la red o controlar los valores introducidos en el entrenamiento y la validación (Alcázar et al. 2008).

Para el aprendizaje supervisado se distinguen dos estructuras principales:

✚ Redes *feed-forward* o *hacia-adelante*: sin bucles o retrocesos en los ajustes de los modelos.

➤ *Monocapa*: formada por una capa de entrada y una de salida.

➤ *Multicapa*: además de las capas de entrada y de salida contienen una o más capas intermedias u *ocultas*. Estas estructuras permiten una mayor capacidad para modelizar una función en concreto (lineal, sigmoidal...) (Figura 13).




Figura 13. Ejemplo de red multicapa. (Hilera y Martínez, 1995)

✚ Redes *feedback* o *recurrent* o *realimentados*: realiza bucles en los ajustes de los modelos.

Se ha comprobado que los modelos de redes neuronales son una alternativa fiable ante los métodos estadísticos tradicionales para relaciones no lineales, relaciones desconocidas o no explícitas, datos con ruido, valores atípicos, datos que no siguen la normalidad ni la independencia, valores correlacionados entre ellos (crecimientos diametrales anuales) y condiciones cambiantes (Alcázar et al., 2008; Diamantopoulou, 2005; Hilbert y Ostendorf, 2001; Lek et al. 1996; Lek and Guégan, 1999; Scrinzi et al., 2007; Vasilakos et al., 2009; NeuralWare 2009). Hasenauer et al.



(2001) desarrolló modelos predictivos de mortalidad para *Picea abies* L. con RNA con mejores resultados que en los modelos tradicionales logísticos, por ejemplo.

Un artículo relacionado con los crecimientos diametrales estudiado en redes neuronales es el de Zhang et al. (2000). En este artículo, se tomaron incrementos diametrales de la especie *Pseudotsuga menziesii* var. *menziesii* [Mirb.] Franco, para estudiar su crecimiento en función de la temperatura y la precipitación mensual de varios años. Otra aplicación forestal de las redes neuronales se deriva del artículo de Gopal y Woodcock (1996) que estudió la mortalidad de coníferas.

2.3.3.1. Desarrollo del modelo de crecimiento diamétrico mediante redes neuronales artificiales

Para desarrollar un modelo mediante redes neuronales es recomendable empezar los ajustes con distintas estructuras de cada modelo. Esto se puede conseguir de dos maneras: una, modificando los valores iniciales aleatorios en la fase de aprendizaje y, dos, probando distinta funciones de transferencia (Hilera y Martínez, 1995).

El procedimiento general para desarrollar una RNA se describe en Klimasauskas (1991), dónde esquemáticamente expone que primero debe realizarse la recogida de datos, seguida de una división de los datos en el laboratorio para la fase de *entrenamiento* y *validación*, una transformación de los datos en inputs entendibles para el software y finalmente una selección de los datos para *entrenar* la red y *validarla*.

Para la predicción del diámetro acumulado en función de otras variables de entrada, se simulará mediante la técnica de correlación en cascada (*the cascade-correlation model*) publicada por Fahlman y Lebiere, 1989, proporcionado por NeuralWorks Predict® (NeuralWare, 2009), descrito en Alcázar *et al.* (2008) y Lu y Harrington (2009). Es un tipo de red multicapa con propagación hacia adelante mediante un aprendizaje supervisado, de forma que, dado un patrón de entrada, las neuronas proporcionan directamente una salida porque no se dan bucles de retroalimentación (Alcázar et al. 2008). La red empieza solamente con las variables de entrada y las de salida. Durante el proceso de *entrenamiento*, se seleccionan nuevas

neuronas de entre un grupo de candidatos y son añadidas en la red como parte de la capa oculta (Balázs, 2009).

La correlación en cascada tiene varias ventajas frente a otras técnicas muy utilizadas y similares como *back-propagation* o *perceptrón* (NeuralWare, 2009):

- ✚ Se autoorganiza automáticamente.
- ✚ Mayor eficiencia en la búsqueda dentro del espacio de soluciones.
- ✚ Entrenamiento más rápido.
- ✚ Forma estructuras de red más compactas y simples.
- ✚ No requiere una gran cantidad de datos iniciales.
- ✚ Crea las capas intermedias o ocultas durante el entrenamiento, por lo tanto, no necesita que se especifiquen el número de capas intermedias para la red, y no se limitan.
- ✚ El entrenamiento de la red es bastante robusto, consiguiendo resultados con pocos ajustes de los parámetros normalmente.
- ✚ Es más difícil que se quede “atrapado” en mínimos locales que en el *perceptrón* multicapa.

En esta variante del perceptrón, establecido por Fahlman y Lebiere en 1990, la arquitectura de la red no se define antes del *entrenamiento*, así, la red comienza su fase de *aprendizaje* sin los nodos intermedios en la capa oculta. La red solamente empieza con las variables de entrada y las neuronas de salida. Por lo tanto, los nodos son *entrenados* separadamente, quedando los pesos fijados en las siguientes etapas y eliminando las variables que no alcancen los resultados esperados.

La red va *aprendiendo* a medida que cambian los pesos de los nodos hasta llegar a un valor predeterminado en una función de evaluación elegida. Esta función compara los mínimos errores o la máxima correlación entre datos de salida (output) y datos observados. Así, a medida que se van introduciendo las nuevas capas, el algoritmo de correlación en cascada, intenta maximizar la correlación entre los datos predichos y el error residual de la red (que se intenta minimizar) (NeuralWare, 2009).

Algunos de los ejemplos del ámbito forestal son los de Vega-García y Chuvieco (2006) que estudian la relación entre la heterogeneidad del paisaje y la ocurrencia de



incendios en el ámbito mediterráneo y Alcázar et al. (2008) que estiman el caudal ecológico para los ríos mediterráneos.

Los valores iniciales introducidos en el software se reflejan en la Tabla 2.

Tabla 2. Variables iniciales.

Altitud	Alt	metros
Pendiente	Pend	%
Densidad	d	pies/ha
Área basimétrica	AB	m ² /ha
Precipitación acumulada anual	P	mm
Temperatura media anual	T	°C
Edad del árbol	E	años

El vector de salida para un tipo de modelo es incremento diametral (ID) y para otro es el diámetro acumulado (DA).

Se seleccionaron las 7 variables de entrada ($X_1 - X_7$) y se combinaron con la base de datos completa y parcial (últimos 10 años de crecimiento, 2001 – 2011), explicado anteriormente en el apartado 2.2.2 de Toma de datos.

Estos datos se dividieron aleatoriamente, según la siguiente partición (Figura 14):

- + Conjunto de datos de entrenamiento: 70%
- + Conjunto de datos de test: 20 %
- + Conjunto de datos de validación: 10 %.

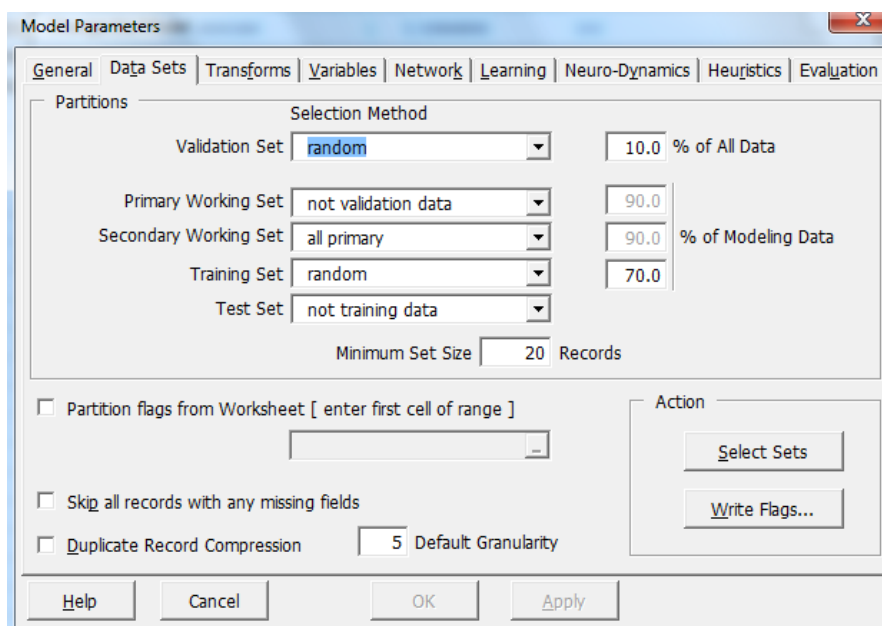


Figura 14. División aleatoria de los datos de entrada en el modelo.

Se probaron varias veces los modelos con diferentes porcentajes de distribución de datos para comprobar su ajuste, variando también las variables de entrada y los valores aleatorios de las conexiones al inicio del entrenamiento.

Una vez terminadas las redes, para comprobar si se ajustaban correctamente se comprobaron distintos parámetros estadísticos y se realizaron análisis de sensibilidad.

Los criterios de selección del mejor modelo predictivo de redes neuronales artificiales fueron (NeuralWare, 2009):

- ✚ Complejidad del modelo: cuantos menos datos de entrada, nodos y salidas tiene el modelo, mejor es.
- ✚ Robustez del modelo: se comparan los valores predichos por el modelo y los valores observados.
- ✚ Precisión de ajuste: el rango de valores va entre 0 y 1. Cuando el valor es próximo a 1, indica bondad de ajuste.
- ✚ Análisis de sensibilidad: sirve para conocer la influencia de las variables de entrada en las de salida.

Finalmente, las redes neuronales que se analizaron en el estudio, están descritas en la tabla de la siguiente página, con su código de identificación.



Tabla 3. Modelos diámetro acumulado e incremento diametral con la base de datos completa y parcial en función de distintas variables.

	Variables de entrada							Código modelo
	E	AB	d	Alt	Pend	T	P	
Diámetro acumulado para base de datos completa	X							EDAD
	X			X	X	X	X	DA1.E-Alt-Pend-T-P
	X			X	X			DA2.E-Alt-Pend
	X					X	X	DA3.E-T-P
Diámetro acumulado para los últimos 10 años	X							EDAD10
	X	X	X	X	X	X	X	DAU1.E-AB-d-Alt-Pend-T-P
	X	X	X	X	X			DAU2.E-AB-d-Alt-Pend
	X	X	X	X				DAU3.AB-d-Alt
	X	X	X					DAU4.E-AB-d
	X					X	X	DAU5.E-T-P
		X	X	X	X	X	X	DAU6.AB-d-Alt-Pend-T-P
Incremento diametral para la base de datos completa	X							INCREMENTO-EDAD
	X			X	X	X	X	ID1.E-Alt-Pend-T-P
	X			X	X			ID2.E-Alt-Pend
	X					X	X	ID3.E-T-P
Incremento diametral para los últimos 10 años	X							INCREMENTO-EDAD10
	X	X	X	X	X	X	X	IDU1.E-AB-d-Alt-Pend-T-P
	X	X	X	X	X			IDU2.E-AB-d-Alt-Pend
	X	X	X	X				IDU3.AB-d-Alt
	X	X	X					IDU4.E-AB-d
	X					X	X	IDU5.E-T-P
		X	X	X	X	X	X	IDU6.AB-d-Alt-Pend-T-P

3. Resultados

3.1. Estadística descriptiva de las bases de datos

En las siguientes tablas se resumen los datos obtenidos de cada parcela (48 en total) y de las rodajas de los árboles individuales.

En la tabla 4 se sintetizan los datos para todas las edades. Por el contrario en la tabla 5 se recopilan las cifras para los últimos 10 años, con las que se realizan posteriormente los ajustes estadísticos.

Tabla 4. Resumen de la base de datos completa.

	Mínimo	Máximo	Promedio	Desviación estándar
Edad, años	1	87	30,840	19,310
Diámetros, cm	0,076	27,122	8,802	5,963
Incrementos diametrales, cm	0,038	1,498	0,299	0,164
Temperatura media anual (°C)	13,191	15,802	14,508	0,516
Precipitación anual acumulada (mm)	402,9	992,9	629,851	153,53

Tabla 5. Resumen de la base de datos parcial (10 últimos años).

	Mínimo	Máximo	Promedio	Desviación estándar
Edad, años (e)	27	87	52,460	13,980
Diámetros, cm (d)	7,428	27,122	15,655	4,268
Incrementos diametrales, cm (id)	0,038	1,498	0,309	0,177
Densidad parcela, nº pies/ha (n)	381,972	2928,451	1506,980	620,656
Altitud, m (alt)	203,325	725,162	472,493	117,495
Pendiente, % (pend)	12,624	102,521	45,2921	15,203
Área basimétrica, m ² /ha (AB)	12,039	49,314	28,4825	8,579
Temperatura media anual °C (T _{anual})	13,4	15,2	14,3	0,576
Precipitación anual acumulada (mm)	469,2	965,6	682,0	167,280



La correlación entre las variables anteriores es estudiada en el software estadístico R (R Core Team, 2014) y se presenta en la tabla 6. Gráficamente pueden observarse en la figura 15.

Tabla 6. Correlación entre las variables.

	Edad (años)	Densidad (pies/ha)	Altitud (m)	Pendiente (%)	Temperatura anual (°C)	Precipitación anual (mm)	Área basimétrica (m ² /ha)	Diámetro acumulado (cm)
Edad (años)	1	-0.131	0.303	0.088	-0.113	-0.043	0.151	0.560
Densidad (pies/ha)	-0.131	1	0.315	-0.055	0	0	0.268	-0.274
Altitud (m)	0.303	0.315	1	0.182	0	0	0.179	-0.121
Pendiente (%)	0.088	-0.055	0.182	1	0	0	0.126	-0.210
Temperatura anual (°C)	-0.113	0	0	0	1	0.091	0	-0.128
Precipitación anual (mm)	-0.043	0	0	0	0.091	1	0	-0.048
Área basimétrica (m ² /ha)	0.151	0.268	0.179	0.126	0	0	1	0.251
Diámetro acumulado (cm)	0.560	-0.274	-0.124	-0.210	-0.128	-0.048	0.251	1

Las variables de entrada no están correlacionadas entre sí ya que ninguna supera el 0.5, factor importante en la metodología ADA, pero no significativo en las redes neuronales, ya que no tienen en cuenta este factor.

3.2. Resultados de la modelización mediante ecuaciones en diferencias algebraicas

En la tabla 7 se resumen los resultados obtenidos de los ajustes de los modelos de las ecuaciones dinámicas, y en la tabla 8 los resultados para los modelos de altura realizada en el trabajo práctico tutorado para las curvas de calidad de la encina (Monfort, 2012).

Tabla 7. Resultados para los modelos de diámetro acumulado – edad.

Código modelo	Parámetros		Error residual estándar (cm)	Error medio absoluto (cm)	Grados de libertad	AKAIKE	BIC	Raíz del error medio cuadrático (RMSE) (cm)
	a	c						
MA	7.365	-0.221	0.1531	0.3140895	574	-523.366	-510.298	0.3222087
BC	88.140	1.247	0.153	0.3142199	574	-523.793	-510.729	0.3221826
HOSS	16.15	0.000063	0.1515	0.3104144	574	-535.656	-522.578	0.3236497
KO	No sig.	0.206	0.1531	0.3142195	574	-523.366	-510.298	0.3221823

Tabla 8. Resultados para los modelos de altura dominante – edad.

Código modelo	Parámetros		Error residual estándar (m)	Error medio absoluto (m)	Grados de libertad	AKAIKE	BIC	Raíz del error medio cuadrático (RMSE) (m)
	a	c						
MA1	32.543	0.863	0.615	8.58726	511	961.391	974.11	10.02305
BC1	6.062	-0.156	0.6234	8.601502	511	974.916	987.63	10.03385
HOSS1	2.028	-0.0024	1.003	8.455150	511	1463.156	1475.8	9.895795
KO1	No sig.	5.09e-09	0.6234	8.601501	511	974.916	987.63	10.03385



Según los resultados de la tabla 7 los valores obtenidos en los estadísticos son muy parecidos, y el modelo que mejor se ajusta, es el de Hossfeld I. Tiene el error residual estándar, el valor de AKAIKE y el de BIC más bajos que el resto, aunque la raíz del error medio cuadrático es superior a los demás valores, no lo es significativamente.

$$d_2 = \frac{t_2^2}{16.15 + t_2 \cdot \left(\frac{t_1}{d_1} - \frac{16.15}{t_1} + 0.000063 \cdot (t_2 - t_1) \right)}$$

Donde:

- d_1 : diámetro acumulado en el t_1 o diámetro observado.
- d_2 : diámetro acumulado en el t_2 o diámetro predicho.
- t_1 : edad del árbol para d_1 o edad de referencia (40 años).
- t_2 : edad del árbol para d_2 o deseado.

Con respecto a la tabla 8 de modelos altura dominante - edad, los resultados también son muy parecidos, aunque se extrae que el mejor modelo es el de McDill-Amateis, por los mismos motivos que en los resultados de diámetro acumulado - edad.

No obstante, si se tienen en cuenta los gráficos de edad - diámetro acumulado para cada modelo, se observa que, para una edad de referencia de 40 años, aproximadamente, todos los modelos se ajustan al crecimiento habitual (Figuras 16, 17, 18, 19). Estas ecuaciones podrían utilizarse para curvas de índice de sitio, ya que resultan unos estadísticos y unos gráficos muy bien ajustados. En este caso, los índices de sitio son 8, 12 y 16 cm de diámetro acumulado para una edad de referencia de 40 años.

Diámetro acumulado - Edad para McDill-Amateis (1992)




Figura 15. Curvas para el modelo McDill-Amateix (1992).

Diámetro acumulado - Edad para Bailey & Clutter (1974)




Figura 16. Curvas para el modelo de Bailey y Clutter (1974).

Diámetro acumulado - Edad para Hossfeld I




Figura 17. Curvas para el modelo Hossfeld I.

Diámetro acumulado - Edad para Korf




Figura 18. Curvas para el modelo Korf.



A su vez, se estudiaron también los residuos gráficamente.




Figura 19. Relación entre predichos y residuos para el modelo Bailey y Clutter (1974).




Figura 20. Relación entre predichos y residuos para el modelo Hossfeld I.




Figura 21. Relación entre predichos y residuos para el modelo McDill-Amateis (1992).




Figura 22. Relación entre predichos y residuos para el modelo Korf.

Se observa que los residuos siguen patrones parecidos, entre -1 y 0.4 cm, coincidiendo con los resultados numéricos de las tablas 7 y 8. Se deduce que los modelos son muy similares entre ellos, aunque hay el de Hossfeld I tiene mejores resultados, en general.

3.3. Resultados de la modelización mediante redes neuronales artificiales

Los resultados obtenidos para las ecuaciones en redes neuronales se representan en distintas tablas, según los datos analizados.

✚ Diagnóstico de los modelos de diámetro (acumulado e incrementos) – edad, sin tener en cuenta ninguna otra variable: tablas 14 y 15. Estos modelos son importantes para entender porqué debe estar incluida la edad.

Tabla 9. Acrónimos de las RNA en función únicamente de la edad.

NOMBRE DE LA RED	BASE DE DATOS	VARIABLE
EDAD	Diámetro acumulado para base de datos completa	Edad
EDAD10	Diámetro acumulado para los últimos 10 años	Edad
INCREMENTO-EDAD	Incremento diametral para la base de datos completa	Edad
INCREMENTO-EDAD10	Incremento diametral para los últimos 10 años	Edad

✚ Diagnóstico de los modelos de diámetro acumulado en función de distintas variables para la base de datos completa: tablas 16, 17 y 18.

Tabla 10. Acrónimos de las RNA para la base de datos completa de diámetros acumulados.

NOMBRE DE LA RED	BASE DE DATOS	VARIABLES				
		Edad	Altitud	Pendiente	Temperatura	Precipitación
DA1. E-Alt-Pend-T-P	Diámetro acumulado para base de datos completa	X	X	X	X	X
DA2.E-Alt-Pend		X	X	X		
DA3.E-T-P		X			X	X



✚ Diagnóstico de los modelos de diámetro acumulado en función de distintas variables para los últimos 10 años: tablas 19, 20 y 21.

Tabla 11. Acrónimos de las RNA para la base de datos de los últimos 10 años de diámetros acumulados.

NOMBRE DE LA RED	BASE DE DATOS	VARIABLES						
		Edad	Área basimétrica	Densidad	Altitud	Pendiente	Temperatura	Precipitación
DAU1.E-AB-d-Alt-Pend-T-P	Diámetro acumulado para los últimos 10 años	X	X	X	X	X	X	X
DAU2.E-AB-d-Alt-Pend		X	X	X	X	X		
DAU3.E-AB-d-Alt		X	X	X	X			
DAU4.E-AB-d		X	X	X				
DAU5.E-T-P							X	X
DAU6.AB-d-Alt-Pend-T-P				X	X	X	X	X

✚ Diagnóstico de los modelos de incremento diametral en función de distintas variables para la base de datos completa: tabla 22.

Tabla 12. Acrónimos de las RNA para la base de datos completa de incrementos diametrales.

NOMBRE DE LA RED	BASE DE DATOS	VARIABLES				
		Edad	Altitud	Pendiente	Temperatura	Precipitación
ID1. E-Alt-Pend-T-P	Incremento diametral para base de datos completa	X	X	X	X	X
ID2.E-Alt-Pend		X	X	X		
ID3.E-T-P		X			X	X

✚ Diagnóstico de los modelos de incremento diametral en función de distintas para los últimos 10 años: tabla 23.

Tabla 13. Acrónimos de las RNA para la base de datos de los últimos 10 años de incrementos diametrales.

NOMBRE DE LA RED	BASE DE DATOS	VARIABLES						
		Edad	Área basimétrica	Densidad	Altitud	Pendiente	Temperatura	Precipitación
IDU1.E-AB-d-Alt-Pend-T-P	Incremento diametral para los últimos 10 años	X	X	X	X	X	X	X
IDU2.E-AB-d-Alt-Pend		X	X	X	X	X		
IDU3.E-AB-d-Alt		X	X	X	X			
IDU4.E-AB-d		X	X	X				
IDU5.E-T-P		X					X	X
IDU6.AB-d-Alt-Pend-T-P				X	X	X	X	X



3.3.1. Modelos de diámetro – edad.

Los resultados de los modelos diámetro – edad en redes neuronales se describen en las tablas siguientes.

Tabla 14. Diagnóstico de los modelos de diámetro (acumulado e incrementos) – edad, sin tener en cuenta ninguna otra variable.

	R ²	Error medio absoluto (cm)	Error máximo absoluto (cm)	Error de la raíz media cuadrática (RMSE) (cm)	Precisión	Datos analizados
Modelo EDAD (arquitectura 2-3-1)						
Entrenamiento	0.9142	1.7237	8.9813	2.3942	0.9567	1778
Test	0.9089	1.8917	9.6997	2.6082	0.9383	762
Validación	0.9147	1.7934	8.0114	2.3868	0.9645	282
Modelo EDAD10 (arquitectura 3-18-1)						
Entrenamiento	0.5974	2.6895	9.9351	3.3271	0.7480	340
Test	0.6837	2.7770	9.1272	3.3856	0.7170	146
Validación	0.6238	2.7159	9.9351	3.3448	0.7386	53
Modelo INCREMENTO-EDAD (arquitectura 3-8-1)						
Entrenamiento	0.2065	0.0599	0.5215	0.0833	0.9274	1778
Test	0.2416	0.0587	0.6013	0.0797	0.9357	762
Validación	0.1539	0.0606	0.3382	0.0811	0.9326	282
Modelo INCREMENTO-EDAD10 (arquitectura 2-8-1)						
Entrenamiento	0.3602	0.0606	0.5446	0.0864	0.9324	340
Test	0.4354	0.0588	0.3279	0.0776	0.9384	146
Validación	0.2311	0.0568	0.2410	0.0770	0.9245	53

En la tabla 10 figura el análisis de sensibilidad para cada modelo.

Tabla 15. Análisis de sensibilidad de las salidas en relación a las variables de entrada para los modelos de diámetro – edad (ED).

	Modelo EDAD	Modelo EDAD10	Modelo INCREMENTO-EDAD	Modelo INCREMENTO-EDAD10
Variable	Edad	Edad	Edad	Edad
Media	0.8005	0.4416	0.0642	-0.3694
Media cuadrática	0.6752	0.4663	0.0850	0.2530
Varianza	0.0343	0.2718	0.0809	0.1167

En las tablas anteriores, 14 y 15, se puede observar la relación que existe entre la edad y los diámetros acumulados a lo largo del tiempo, pero con unos errores altos, lo que señala la necesidad de introducir otros parámetros o variables que disminuyan su variabilidad.

En los modelos con incrementos diametrales de la base de datos completa aparece una R^2 muy baja, con la edad positiva. Por el contrario, en la base de datos parcial (últimos 10 años), la edad tiene un peso negativo. Esto podría deberse a que el *Quercus ilex subsp. ilex* L. crece a menor ritmo en los datos finales tomados, debido a que a medida que pasan los años, disminuye su potencial de crecimiento.

3.3.2. Modelos de diámetro acumulado en función de distintas variables para la base de datos completa.

En las tablas siguientes se muestran los resultados y el análisis de sensibilidad para cada modelo de diámetro acumulado en función de distintas variables iniciales.

Tabla 16. Diagnóstico de los modelos de diámetro acumulado en función de distintas variables para la base de datos completa.

	R^2	Error medio absoluto (cm)	Error máximo absoluto (cm)	Error de la raíz media cuadrática (RMSE) (cm)	Precisión	Datos analizados
Modelo DA1 (arquitectura 3-29-1) E – Alt – Pend – T – P						
Entrenamiento	0.9865	0.6857	6.0327	0.9814	0.9994	1778
Test	0.9837	0.7695	5.468	1.0829	0.9987	762
Validación	0.9822	0.7852	4.3401	1.1507	1	282
Modelo DA2 (arquitectura 5-28-1) E – Alt – Pend						
Entrenamiento	0.9849	0.7294	8.8511	1.0536	0.9971	1778
Test	0.9823	0.7591	9.5508	1.0928	0.9960	762
Validación	0.9784	0.7736885	9.4738	1.2096	0.9927	282
Modelo DA3 (arquitectura 5-27-1) E – T – P						
Entrenamiento	0.6520	3.4816	15.8091	4.4552	0.7854	1778
Test	0.6703	3.6561	16.3112	4.5791	0.7973	762
Validación	0.6279	3.9018	14.8012	5.0721	0.7164	282

Los resultados obtenidos en la tabla 16 indican un mejor ajuste del diámetro acumulado en función de las variables iniciales, donde la R^2 llega a un 0.98 en dos de



los tres casos. En ellos, los errores son muy parecidos. Además, la precisión raramente llega a 1.


En la red DA3, formada por las variables iniciales de edad, temperatura y precipitación, su R^2 es muy baja, indicando que las variables climáticas son insuficientes para explicar el crecimiento.

Tabla 17. Análisis de sensibilidad de las salidas en relación a las variables de entrada para los mejores modelos de diámetro acumulado para la base de datos completa.

Modelo DA1					
	Edad	Altitud	Pendiente	Tanual	Panual
Media	0.8214	-0.3966	-0.0507	0	0
Media cuadrática	0.8494	2.4750	3.2424	0	0
Varianza	0.1747	2.3185	3.2410	0	0
Modelo DA2					
	Edad	Altitud	Pendiente		
Media	0.8569	-0.2201	-0.3838		
Media cuadrática	0.9072	13.8460	19.1709		
Varianza	0.1730	13.8026	19.0305		

Teniendo en cuenta los resultados de las tablas 16 y 17, el modelo que mejor se ajusta es el DA2, de edad, altitud y pendiente, siguiendo el principio de simplicidad, ya que, comparando los residuos en las gráficas de la tabla 13 con el modelo DA1 (E-Alt-Pend-T-P), no hay diferencias significativas.

Tabla 18. Gráficos de valores predichos y residuos para los mejores modelos de diámetro acumulado en función de distintas variables para la base de datos completa.



Gráficamente no se aprecian diferencias significativas entre los residuos de los dos mejores modelos para la base de datos completa.

3.3.3. Modelos de diámetro acumulado en función de distintas variables para los últimos 10 años.

En las tablas 19 y 20, y en las figuras de la tabla 16, se presentan los resultados de las redes neuronales para diámetro acumulado en los últimos 10 años, junto con las variables introducidas.

Tabla 19. Diagnóstico de los modelos de diámetro acumulado en función de las variables para los últimos 10 años.

	R ²	Error medio absoluto (cm)	Error máximo absoluto (cm)	Error de la raíz media cuadrática (RMSE) (cm)	Precisión	Datos analizados
Modelo DAU1 (arquitectura 6-26-1) E – AB – d – Alt – Pend – T – P						
Entrenamiento	0.9963	0.2742	1.4392	0.3665	1	340
Test	0.9923	0.3817	2.3698	0.5179	1	146
Validación	0.9937	0.3613	2.1369	0.5212	1	53
Modelo DAU2 (arquitectura 7-23-1) E – AB – d – Alt – Pend						
Entrenamiento	0.9955	0.2859	1.8594	0.3888	1	340
Test	0.9914	0.3979	3.1014	0.5956	1	146
Validación	0.9891	0.4862	2.1555	0.6923	1	53
Modelo DAU3 (arquitectura 6-28-1) E – AB – d – Alt						
Entrenamiento	0.9940	0.3200	1.8436	0.4499	1	340
Test	0.9916	0.4114	2.6144	0.5817	1	146
Validación	0.9943	0.3913	1.8355	0.5226	1	53
Modelo DAU4 (arquitectura 7-29-1) E – AB – d						
Entrenamiento	0.9857	0.2605	1.2800	0.3589	1	340
Test	0.9674	0.3689	1.9866	0.5263	0.9930	146
Validación	0.9536	0.4207	3.285	0.6875	0.9808	53
Modelo DAU5 (arquitectura 4-9-1) E – T – P						
Entrenamiento	0.6410	2.5455	9.2515	3.2208	0.7718	340
Test	0.5419	3.1351	9.4174	3.7374	0.6503	146
Validación	0.7426	2.3855	6.4479	2.9791	0.7692	53
Modelo DAU6 (arquitectura 6-17-1) AB – d – Alt – Pend – T – P						
Entrenamiento	0.9676	0.8526	3.9568	1.0740	0.9970	340
Test	0.9665	0.9297	3.0127	1.1580	1	146
Validación	0.9464	0.9811	3.2566	1.2680	1	53



Comparando los resultados estadísticos, según la R^2 , la mayoría de los modelos reflejan muy bien el crecimiento diametral de la encina.

Como ocurría en los modelos anteriores para la base de datos completa, las variables de edad, temperatura y precipitación (DAU5), no tienen muy buen ajuste. Por lo tanto, se seleccionaron otros modelos.

En los modelos DAU1 (E-AB-d-Alt-Pend-T-P) y DAU2 (E-AB-d-Alt-Pend), los resultados son muy buenos, aunque observando la tabla 14 de análisis de sensibilidad de los mejores modelos, la temperatura y la precipitación no tienen ningún peso en el DAU1, por lo tanto, entre ellos, el modelo que mejor se ajusta al crecimiento es el DAU2, con menos variables de entrada, e igual R^2 .

Por lo que respecta a la red DAU3 (E-AB-d-Alt), su estructura es mucho más compleja (6-28-1) que DAU2 (7-23-1), con una R^2 más baja y unos errores muy dispersos. Y DAU4 (E-AB-d) su precisión no llega a ser 1.

Finalmente, la red DAU6 (AB-d-Alt-Pend-T-P), no tiene en cuenta la edad, y aunque los resultados son bastante buenos, los errores son superiores al resto de redes, y su R^2 es sensiblemente menor.

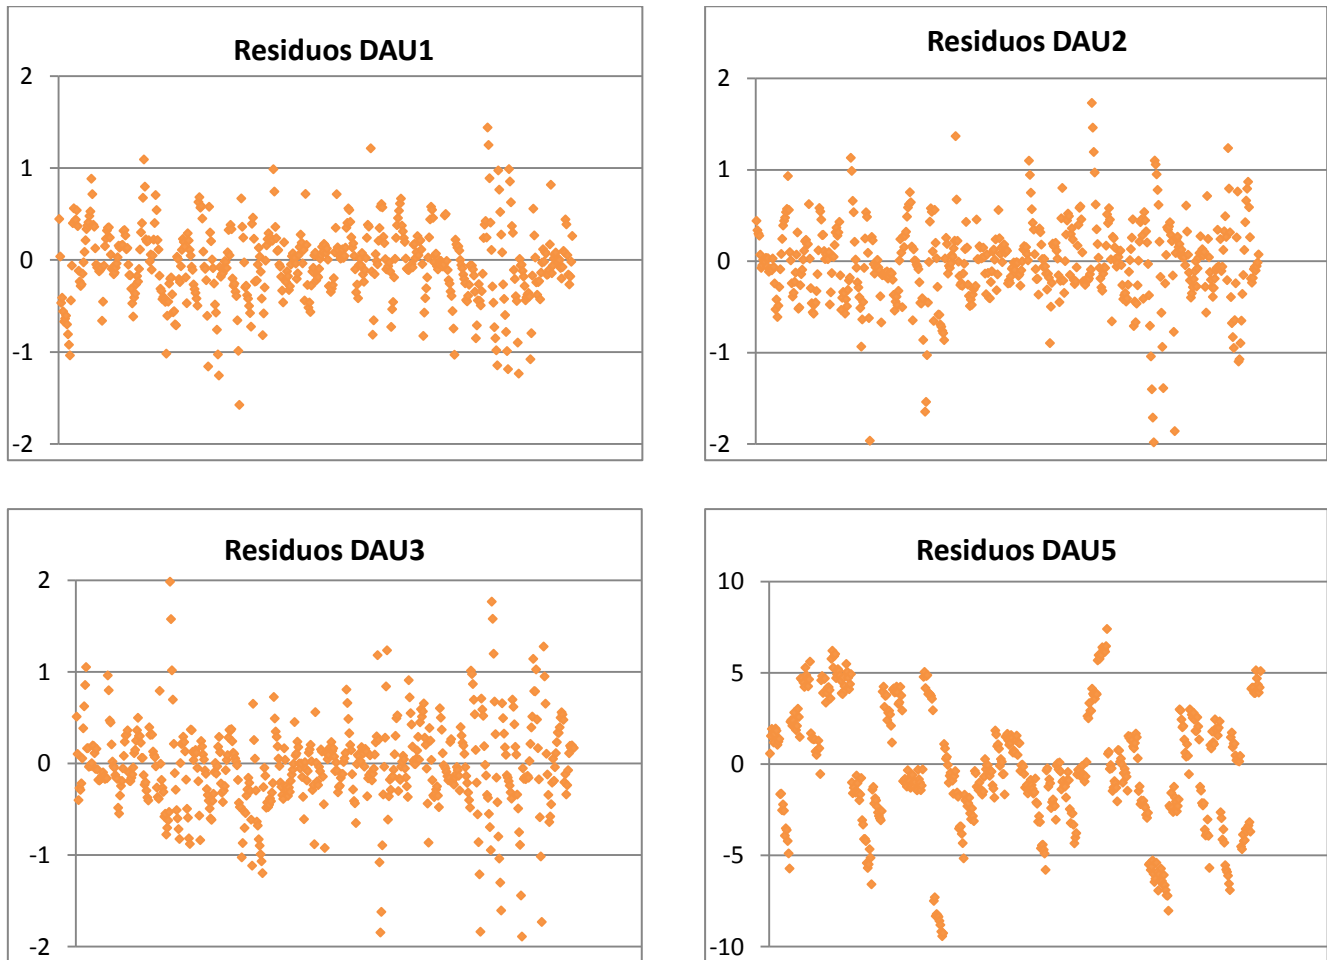
Tabla 20. Análisis de sensibilidad de las salidas en relación a las variables de entrada para los mejores modelos de diámetro acumulado en función de variables para los últimos 10 años.

Modelo DAU1							
	Edad	Densidad	Altitud	Pendiente	Área basimétrica	T anual	Panual
Media	0.8398	-0.6678	-0.0944	-0.5958	0.0297	0	0
Media cuadrática	1.0407	2.9618	1.9358	0.6177	2.7581	0	0
Varianza	0.3361	2.5210	1.9306	0.2632	2.7624	0	0
Modelo DAU2							
	Edad	Densidad	Altitud	Pendiente	Área basimétrica		
Media	0.7468	-0.2596	-0.1582	-0.5075	0.2767		
Media cuadrática	1.0901	3.12760	1.8475	1.3110	1.0926		
Varianza	0.5334	3.0660	1.8259	1.0555	1.0179		
Modelo DAU3							
	Edad	Densidad	Área basimétrica	Altitud			
Media	0.7361	-0.1730	0.2089	-0.5024			
Media cuadrática	0.8178	3.0101	2.1298	15.822			
Varianza	0.2765	2.9859	2.0901	15.5990			
Modelo DAU5							
	Edad	Tanual	Panual				
Media	0.4624	-0.0050	0				
Media cuadrática	0.4759	0.0063	0				
Varianza	0.2626	0.0063	0				

En los análisis de sensibilidad se denotan las influencias o pesos de cada variable en la red. Para el mejor modelo de este grupo, DAU2 (E-AB-d-Alt-Pend), la edad es positiva y el resto de variables, densidad, altitud y pendiente, representan influencia negativa, respecto al crecimiento.



Tabla 21. Gráficos de valores predichos y residuos para los mejores modelos de diámetro acumulado en función de variables de individuo y de rodal para los últimos 10 años.



El modelo DAU5 (E-T-P) presenta residuos de gran magnitud porque solamente tiene en cuenta la edad, la temperatura y la precipitación, insuficientes para explicar el crecimiento. En cambio, las demás redes, presentan unos residuos bastante similares en magnitud.

3.3.4. Modelos de incremento diametral en función de distintas variables para la base de datos completa.

En la tabla sucesiva se presentan los resultados de las redes para incrementos diametrales de toda la base de datos con las variables de entrada.

Tabla 22. Diagnóstico de los modelos de incremento diametral en función de variables para la base de datos completa.

	R^2	Error medio absoluto (cm)	Error máximo absoluto (cm)	Error de la raíz media cuadrática (RMSE) (cm)	Precisión	Datos analizados
Modelo ID1 (arquitectura 7-22-1) E – Alt – Pend – T – P						
Entrenamiento	0.4705	0.0529	0.5904	0.0741	0.9516	1778
Test	0.4232	0.0539	0.4046	0.0743	0.9436	762
Validación	0.4159	0.0542	0.4801	0.0800	0.9291	282
Modelo ID2 (arquitectura 7-30-1) E – Alt – Pend						
Entrenamiento	0.4953	0.0522	0.6095	0.0746	0.9404	1778
Test	0.4422	0.0507	0.3928	0.0700	0.9528	762
Validación	0.4518	0.0545	0.3277	0.0763	0.9433	282
Modelo ID3 (arquitectura 6-3-1) E – T – P						
Entrenamiento	0.2298	0.0588	0.5973	0.0797	0.9353	1778
Test	0.2806	0.0593	0.5151	0.0843	0.9239	762
Validación	0.2109	0.0591	0.4845	0.0841	0.9504	282

La precisión de los modelos no llega a 1 y las R^2 son muy bajas. Debido a estos resultados se evidencia que estas variables son insuficientes para entender el crecimiento diamétrico de la encina.



3.3.5. Modelos de incremento diametral en función de distintas variables para los últimos 10 años.

En esta última tabla 23 se exponen los resultados para las redes de incrementos diametrales de los últimos 10 años, con todas las variables de entrada en diferentes combinaciones.

Tabla 23. Diagnóstico de los modelos de incremento diametral en función de variables para los últimos 10 años.

	R ²	Error medio absoluto (cm)	Error máximo absoluto (cm)	Error de la raíz media cuadrática (RMSE) (cm)	Precisión	Datos analizados
Modelo IDU1 (arquitectura 6-17-1) E – AB – d – Alt – Pend – T – P						
Entrenamiento	0.6512	0.0500	0.5233	0.0744	0.9520	340
Test	0.5723	0.0443	0.2576	0.0596	0.9790	146
Validación	0.6220	0.0526	0.2249	0.0651	0.9808	53
Modelo IDU2 (arquitectura 10-25-1) E – AB – d – Alt – Pend						
Entrenamiento	0.7497	0.0412	0.3455	0.0597	0.9700	340
Test	0.6541	0.0471	0.4370	0.0721	0.9511	146
Validación	0.5140	0.0502	0.158	0.0661	0.9808	53
Modelo IDU3 (arquitectura 6-29-1) E – AB – d – Alt						
Entrenamiento	0.6728	0.0453	0.3696	0.0643	0.9610	340
Test	0.6245	0.0550	0.4723	0.0804	0.9441	146
Validación	0.5995	0.0415	0.1539	0.0540	0.9808	53
Modelo IDU4 (arquitectura 3-12-1) E – AB – d						
Entrenamiento	0.4331	0.0597	0.4441	0.0817	0.9309	340
Test	0.5703	0.0535	0.5263	0.0791	0.9650	146
Validación	0.3357	0.0521	0.1314	0.0612	1	53
Modelo IDU5 (arquitectura 4-14-1) E – T – P						
Entrenamiento	0.3070	0.0587	0.5554	0.0813	0.9323	340
Test	0.4585	0.0637	0.4582	0.0898	0.9178	146
Validación	0.4039	0.0620	0.2815	0.0814	0.9623	53
Modelo IDU6 (arquitectura 5-19-1) AB – d – Alt – Pend – T – P						
Entrenamiento	0.6150	0.0470	0.4833	0.0677	0.964	340
Test	0.5132	0.0581	0.5633	0.0885	0.9371	146
Validación	0.5546	0.0421	0.1489	0.0557	0.9808	53

En este caso, las R² demuestran un mejor ajuste que las redes entrenadas para la base de datos completa de incrementos diametrales. Los modelos están bastante bien

ajustados, sobretodo el IDU2, con todas las variables, excepto las climatológicas, con una R2 en el entrenamiento de 0.75.

Pero comparándolo con los resultados de los modelos con diámetro acumulado para los últimos 10 años y para la base de datos completa, los incrementos diametrales dan un peor ajuste, para las mismas variables de entrada.

Al descartar los modelos de incrementos diamétricos, se pierde información significativa de los crecimientos anuales, pero se gana robustez y fiabilidad en los modelos acumulados.



4. Implicaciones para la gestión y discusión

Comparando los mejores resultados obtenidos para los modelos de diámetro acumulado y altura dominante mediante la metodología ADA, se verifica que el modelo mejor ajustado es el de Hossfeld I para la base de datos completa de diámetros acumulados, con una raíz del error medio cuadrático de 0,324 y un error residual estándar de 0,152. En base a estos resultados, se determina que el modelo que mejor explica el crecimiento es el diamétrico acumulado.

Por otro lado, cotejando los resultados mediante la metodología de redes neuronales artificiales (RNA), para los modelos de diámetro acumulado de la base de datos completa la variabilidad es muy elevada. A su vez, la R^2 es de 0.98. Para los de la base de datos parcial, su variabilidad es menor que los modelos anteriores, y con una R^2 de 0.99 en los mejores resultados. A diferencia de lo anterior, las redes con los incrementos diametrales como variable dependiente, solamente obtienen una R^2 de 0.6. Por lo tanto, las mejores redes que se ajustan al crecimiento son las que tienen en cuenta los diámetros acumulados para los últimos 10 años, concretamente la red con los factores de edad, área basimétrica, densidad, pendiente y altitud, y una arquitectura de 7-23-1. Finalmente, las variables introducidas en los modelos de las RNA que mejor explican el crecimiento de la encina para los 10 años últimos son: densidad, altitud, área basimétrica, pendiente y edad. Por ejemplo, en casos con alta densidad, el crecimiento es menor, justificando una gestión sostenible que consiga la disminución de la densidad en algunas zonas aumentando el diámetro de los árboles para conseguir una mayor cantidad de madera. Para altitudes elevadas con pendientes pronunciadas, como ocurre en el Parque, su velocidad de crecimiento es menor.

En lo que respecta al área basimétrica, tiene una caracterización especial. La relación positiva del área basimétrica se entiende como un aumento del diámetro que hace incrementar también el área basimétrica. Esto es debido al efecto de unos pies uniformes, con características de competencia constantes a lo largo de los 10 años.

La influencia de la temperatura media anual y la precipitación acumulada anual no se tiene en consideración para ajustar el crecimiento anual. Por el contrario, sí hay estudios que relacionan estas dos variables con el incremento diametral dentro de un

año, es decir, los incrementos entre el crecimiento de primavera e invierno (Martín Pérez et al., 2009).

Hay dos características muy significativas en los modelos ajustados con los incrementos diametrales. Por un lado, la relación entre diámetro y edad para la base de datos completa resulta positiva (a mayor edad, mayor incremento diametral), pero en la base de datos parcial, la misma relación, es negativa. Ésto es debido al peso más significativo que se le atribuye a los crecimientos iniciales de la especie en la base de datos completa, con crecimientos más acusados al principio i más pequeños al final. En cambio, dentro de la base de datos parcial, la relación entre edad y incremento diametral se explica debido al contenido de dicha base, centrada en los últimos 10 años, de crecimiento más lento para la especie. Estas relaciones entre las variables deben tenerse en cuenta para hacer los modelos de gestión, ya que, según el rango de edades que se quiera modelizar, deberán utilizarse unos modelos u otros.

Una vez conocidos los mejores modelos para cada metodología, se contrastan y analizan sus resultados. Entre ellos se concluye que el mejor modelo presentado es el de diámetro acumulado para la base de datos completa mediante la metodología ADA de Hossfeld I. Los residuos de la ecuación Hossfeld I tienen mucha menos variabilidad que los residuos producidos por la RNA. Junto con ello, cabe destacar la importante diferencia en la cantidad de variables que tiene la red, que no tiene la ecuación dinámica.

Este modelo de Hossfeld I, puede aplicarse a la totalidad del crecimiento de los diámetros, hasta la edad máxima de la base de datos. Por el contrario, la mejor RNA solamente puede aplicarse a la gestión que se pueda llevar a cabo 10 años después de este proyecto, manteniendo constantes las variables introducidas. Por este motivo, se recomendaría volver a ajustar la red, con nuevos datos, pasados 10 años, ya que, las condiciones pueden variar debido, por ejemplo, a un cambio de gestión.

Una vez establecida la caracterización del encinar en función de la edad, se puede implementar para la gestión del parque desde el punto de vista del uso público. Como por ejemplo, se podría crear un sendero a lo largo del Parque, que incluya árboles monumentales, de forma que se gestionarían los espacios circundantes en función de la densidad, área basimétrica, altitud, pendiente y edad de las redes.



Por otra parte, también tiene su interés en el ámbito privado. Es una variable de entrada para las ecuaciones de cubicación proporcionadas por el Tercer Inventario Forestal Nacional, mediante las cuales, se puede saber el volumen de madera disponible. Con el cálculo de los posibles volúmenes de una parcela, se conocerían los rendimientos económicos que les daría una masa a una determinada edad. Ésto va ligado al conocimiento de la capacidad productiva de estos montes. Los gestores pueden utilizar esta herramienta para conocer los diámetros que se podrían obtener a una determinada edad, según las calidades de estación diamétricas (8, 12 o 16) a la edad de referencia de 40 años, y planificar el aprovechamiento de la madera de acuerdo a un criterio tecnológico.

Finalmente, para conseguir aumentar los diámetros, en el caso de una intención productiva de leñas, se recomendaría cortar las encinas con peor crecimiento para disminuir la densidad en las zonas bajas de las laderas, para así aumentar más rápidamente los diámetros, pero dejar densidades medias o altas en las partes superiores, para perpetuar la protección de esas partes y evitar deslizamientos en las zonas con más pendientes. Al mismo tiempo, se conseguiría disminuir el riesgo de incendios que actualmente existe en la vertiente mediterránea.

5. Bibliografía

Akaike H. (1974) A new look at the statistical model identification. IEE Transaction on Automatic Control, Vol. AC-19, núm. 6, p. 716-723.

Alcázar J., Palau A. y Vega-García C. (2008). A neural net model for environmental flow estimation at the Ebro River Basin, Spain. *Journal of Hydrology*. Vol. 349, núm. 1-2, p. 44-55.

Amaro A., Reed D., Tomé M. y Themido I. Modeling Dominant Height Growth: Eucalyptus Plantations in Portugal. (1998) *Forest Science*. Vol. 4, Núm. 1, p. 37-46.

Bailey R. y Clutter J. (1974) Base-age invariant polymorphic site curve. *Forest Science*. Núm. 20, p. 155-159.

Balázs G. (2009) Cascade-Correlation Neural Networks: a survey. *Technical Report*, University of Alberta.

Barrio-Anta M., Castedo-Dorado F., Diéguez-Aranda U., Álvarez-González J.G. y Parresol B.R., Rodríguez-Soalleiro R. (2006). Development of a basal area growth system for maritime pine in northwestern Spain using the generalized algebraic difference approach. *Canadian Journal of Forest Research*. Vol. 36, núm. 6, p. 1461.

Barrio-Anta M., Álvarez P.A., Khouri E.A., Castedo-Dorado F. y Obregón A.C. (2012) Predicción del índice de sitio a partir de variables ambientales y de concentración foliar de nutrientes en masas regulares de *Pinus pinaster* Ait. en Asturias. *Cuadernos de la Sociedad Española de Ciencias Forestales*, Núm. 34, p. 39-46.

Barrio-Anta M. y Diéguez-Aranda U. (2005) Site quality of pedunculate oak (*Quercus robur* L.) stands in Galicia (northwest Spain). *European Journal of Forest Research*. Vol. 124, núm. 1, p. 19-28.

Bravo F., Álvarez-González J.G., del Río M., Barrio-Anta M., Bonet J.A., Bravo-Oviedo A., Calama R., Castedo-Dorado F., Crecente-Campo F., Condés S., Diéguez-Aranda U., González-Martínez S.C., Lizarralde I., Nanos N., Madrigal A., Martínez-Millán F.J., Montero G., Ordóñez C., Palahí M., Piqué M., Rodríguez F., Rodríguez-Soalleiro R., Rojo A., Ruiz-Peinado R., Sánchez-González M.O., Trasobares A. y Vázquez-Piqué J. (2012) Growth and yield models in Spain: historical overview, contemporary examples and perspectives. Instituto Universitario de Investigación en Gestión Forestal



Sostenible (Universidad de Valladolid-INIA), Unidad de Gestión Forestal Sostenible (Universidad de Santiago de Compostela). 76 pp. ISBN: 978-84-615-7145-1.

Bueno-López S. y Bevilacqua E. (2013) Diameter growth prediction for individual *Pinus occidentalis* Sw. trees. *iForest - Biogeosciences and Forestry*. Vol. 6 núm. 4, p. 209–216.

Cieszewski C. y Bailey R. (2000) Generalized Algebraic Difference Approach: Theory based derivation of dynamic site equations with polymorphism and variable asymptotes. *For. Sci.* 46: 116-126.

Cieszewski C.J. y Bella I.E. (1989) Polymorphic height and site index curves for lodgepole pine in Alberta. *Canadian Journal of Forest Research*. Vol. 19, núm. 19, p. 1151-1160.

Clutter J., Fortson J., Pienaar L., Brister H. y Bayley R. (1983) *Tiember management: a quantitative approach*. New York. Ed John Willey & Sons. 333 p.

Condés S., Vaquero M.F. y García F. (2012) Influencia del clima en el crecimiento del volumen del rodal. Aplicación a masas de "*Pinus Halepensis*" Mill. en la provincia de Murcia. *Cuadernos de la Sociedad Española de Ciencias Forestales*. Núm. 34, p. 67-78.

Corchado, J.M. (2000) *Redes neuronales artificiales: un enfoque práctico*. Vigo. Servicio de Publicaciones de la Universidad de Vigo.

Crecente-Campo F. (2008) *Modelo de crecimiento de árbol individual para "Pinus radiata" D. Don en Galicia*. Tesis doctoral. Universidad de Santiago de Compostela. Servizo de Publicacións e Intercambio Científico. ISBN: 978-84-9887-037-4.

Diéguez-Aranda U., Castedo-Dorado, F. C. y Álvarez-González J.G. (2005) Funciones de crecimiento en área basimétrica para masas de *Pinus sylvestris* L. procedentes de repoblación en Galicia. *Investigación agraria. Sistemas y recursos forestales*. Vol. 14, núm. 2, p. 253-266.

Diéguez-Aranda U., Rojo A., Castedo-Dorado F., Álvarez González J.G., Barrio-Anta M., Crecente-Campo F., González González J.M., Pérez-Cruzado C., Rodríguez Soalleiro R., López-Sánchez C.A., Balboa-Murias M.A., Gorgoso Varela J.J. y Sánchez Rodríguez F. (2009) *Herramientas silvícolas para la gestión forestal sostenible en Galicia*. Xunta de Galicia. ISBN: 978-84-692-7395-1.

Diputació de Barcelona (2014). *Diputació de Barcelona*. [Citado 2014/feb/25]. <http://parcs.diba.cat/>

DGCN. 2001. Mapa Forestal de España. Escala 1:50.000. Catalunya. Dirección General de Conservación de la Naturaleza, Ministerio de Medio Ambiente, Madrid.

EEA, 2008. Impacts of Europe's changing climate (2008). An indicator-based assessment (EEA Report No 4/2008). Office for Official Publications of European Communities, Luxembourg. 246 p.

Elfving B. y Kiviste A. (1997) Construction of site index equations for *Pinus sylvestris* L. using permanent plot data in Sewden. *Forest Ecology and Management*. Vol. 98, núm. 2, p.125-134.

Fahlman S.E. y Lebiere C. (1989) The cascade-Correlation learning architecture. En: *Advances in Neural Information Processing Systems 2*. Kaufmann M. p. 524-532.

Faucett L. (1994) Fundamentals of Neural Networks: Architectures, Algorithms, and Applications, Prentice Hall.

Gea-Izquierdo G., Cañellas I. y Montero G. (2008) Site index in agroforestry systems: age-dependent and age-independent dynamic diameter growth models for *Quercus ilex* L. in Iberian open oak woodlands. *Canadian Journal of Forest Research*. Vol. 38, p. 101-113.

Gené C., Esplata M.J., Gracia M. y Retana J. (1993). Identificación de los anillos anuales de crecimiento de la encina (*Quercus ilex* L.). *Orsis*. Vol. 8, p. 127-139.

González J. y Ibarz P. (1998) Monte bajo irregular de encina: Caracterización silvícola. *Sistemas y Recursos Forestales*. Vol. 7, núm. 1-2, p. 95-108.

Gopal S. y Woodcock C. (1996) Remote sensing of forest change using artificial neural networks. *IEEE Transactions on Geoscience and Remote Sensing*. Vol. 34, núm.2, p. 398-404.

Grothendieck G. (2013). nls2: Non-linear regression with brute force.

Hasenauer H., Merkl D. y Weingartner M. (2001) Estimating tree mortality of Norway spruce stands with neural networks. *Advances in Environmental Research*. Vol. 5, p. 405-414.

Hilbert D.W. y Ostendorf B. (2001) The utility of artificial neural networks for modeling the distribution of vegetation in past, present and future climates. *Ecological modeling*. Vol. 146, p. 311-327.



Hilera González J.R. y Martínez V.J. (1995) Redes neuronales artificiales: fundamentos, modelos y aplicaciones. RA-MA S.A. ISBN: 8478971556.

Ibáñez-Martí J.J. y Mata-Bretón T. (2006) Análisis de la distribución de los encinares en Cataluña. *Barcelona: Centre de Recerca Ecològica i Aplicacions Forestals*.

Klimasauskas C.C. (1991) Applying Neural Networks. Part 3: Training a Neural Network. *PC/AI Magazine*. Vol. 5, p. 20-40.

Lek S. y Guégan J.F. (1999) Artificial neural networks as a tool in ecological modeling, an introduction. *Ecological Modelling*, Vol. 120, p. 65-73.

Lek S., Delacoste M., Baran P., Dimopoulos I., Lauga J. y Aulagnier S. (1996) Application of neural networks to modelling nonlinear relationships in ecology. *Ecological modeling*. Vol.. 90 p. 9-73.

Lemon, J. (2006) Plotrix: a package in the red light district of R. *R-News*, 6(4): 8-12.

López-Senespleda E. y Sánchez-Palomares O. (2007). Modelo de calidad de estación y crecimiento en altura dominante para *Quercus faginea* Lam. en España. *Cuadernos de la Sociedad Española de Ciencias Forestales*. Vol. 23, p. 199-205.

López-Senespleda E. y Sánchez Palomares O. (2008) Caracterización del hábitat y áreas potenciales fisiográfico-climáticas del Quejigo ("*Quercus faginea*" Lam.) en la provincia de Guadalajara. *Cuadernos de la Sociedad Española de Ciencias Forestales*. Núm. 25, p. 267-272.

Lu W. y Harrington P.B. (2009) Radial basis function cascade correlation networks. *Algorithms*. Vol. 2, p. 1045-1068.

Martín Pérez D., Alejano Monge R., Vázquez Piqué J. y Tapias R. (2009). Evolución del crecimiento radial de *Quercus ilex* L. ssp. *ballota* (Desf.) Samp.) y *Quercus suber* L. en la provincia de Huelva. Influencia de parámetros climáticos, selvícolas y humedad de suelo. *V Congreso Forestal Nacional*, Ávila, 21-25 Septiembre 2009, p.1-14.

Mayor, X. y Rodá, F. (1993) Growth response of holm oak (*Quercus ilex* L.) to commercial thinning in the Montseny mountains (N.E. Spain). *Annals of Forest Science*. Vol. 50, p. 247-256.

Mehtdtalo, L. (2008). Forest Biometrics with examples in R. Lecture notes for the forest biometrics course. 186 pages

Monfort, I.P.; Treball Pràctic Tutorat “*Determinació de les corbes de qualitat d’estació del Quercus ilex L. al Parc Natural del Montnegre i el Corredor*”. Trabajo Práctico Tutorado. Universitat de Lleida, 2012).

NeuralWare (2009) NeuralWorks Predict®. The complete solution for neural data modeling. NeuralWare, Pittsburg, PA, USA.

Orchis Naturalistes. La natura a la baixa Tordera [Blog Internet]. España. *Orchis Naturalistes*. 2010 noviembre - [Citado 2014/feb/13]. <http://natura-tordera.blogspot.com.es/search/label/Baixa%20Tordera%20-%20Descripcions%20generals>

Øyen B.H., Nilsen P., Bøhler F. y Andreassen K. (2012) Predicting individual tree and stand diameter increment responses of Norway spruce (*Picea abies* L.) after mountain forest selective cutting. *Forests Studies/Metsanduslikud Uurimused*. Vol. 55, p. 33-45.

Palahí M., Pukkala T., Kasimiadis D., Poirazidis K. y Papageorgiou A.C. (2008) Modelling site quality and individual-tree growth in pure and mixed *Pinus brutia* stands in north-east Greece. *Annals of Forest Science*. Vol. 65, núm. 5, p. 501.

Pardé J. y Bouchon J. (1994) *Dasometría*. Madrid: Paraninfo. ISBN: 8428320683.

Pena E.A. y Slate E.H. (2006). "Global Validation of Linear Model Assumptions," *J. American Statistical Association*, 101(473):341-354.

Peña D., 2002. *Regresión y diseño de experimentos*. Alianza Editorial, Madrid, 744 p.

Pinheiro J, Bates D, DebRoy S, Sarkar D and R Core Team (2014). *nlme: Linear and Nonlinear Mixed Effects Models*. R package version 3.1-117

Pretzch H. (2010) *Forest dynamics, growth and yield*. Munich. Ed Springer. 425-436.

Pulido F. y Picardo A. (2010) Libro Verde de la Dehesa. Debate hacia una Estrategia Ibérica de gestión. *Junta de Castilla y León, Sociedad Española de Ciencias Forestales, Sociedad Española para el Estudio de los Pastos, Asociación Española de Ecología Terrestre y Sociedad Española de Ornitología*.

R Core Team (2014) *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. Vienna, Austria. URL: <http://www.R-project.org/>



Retana J., Gracia M. y Espelta J.M. Caracterización de masas mixtas de pino carrasco y encina en el macizo del Montseny (Noreste de la Península Ibérica). *Cuadernos de la Sociedad Española de Ciencias Forestales*. Núm. 3, p. 167–179.

Rodá F., Retana J., Gracia C.A. y Bellot J. (1999) Ecology of Mediterranean evergreen oak forests. New York. Ed. Springer.

Safi Y. y Bouroumi A. (2013) Prediction of forest fires using artificial neural networks. *Applied Mathematical Sciences*. Vol. 7, núm. 6, p. 271 – 286.

Sánchez-González M., Tomé M., Montero G. (2005) Modelling height and diameter growth of dominant cork oak trees in Spain. *Annals of Forest Science*, vol. 62, p. 633-643.

Sánchez-González M., Cardillo E., Camacho E., Garriga E. y Cañellas I. (2009) Modelo de crecimiento en diámetro para alcornoque en sistemas dehesados. V Congreso Forestal Nacional, Ávila, 21-25 Septiembre 2009, núm. 153, p.1–13.

Schwarz G.E. (1978). Estimating the dimension of a model. *Annals of Statistics*. Vol. 6, núm. 2, p. 461-464.

Scrinzi G., Marzullo L. y Galvagni D. (2007) Development of a neural network model to update forest distribution data for managed alpine stands. *Ecological modeling*. Vol. 206, p. 331-346.

Soil Survey Staff (2014) Keys to Soil Taxonomy, 12th ed. USDA-Natural Resources Conservation Service, Washington, DC.

Tercer Inventario Forestal Nacional 1997 – 2007 [Recurso electrónico]. España. Ministerio de Agricultura, Alimentación y Medio Ambiente [Citado 2014/abr/20]. <http://www.magrama.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/ifn3.aspx>

Terradas J. y Romane F. (1992) *Quercus ilex* L. ecosystems : function, dynamics and management. Kluwer Academic Publishers, Dordrecht, p. 376.

Torres Álvarez E., Alejano Monje R. y Alaejos Gutierrez J. Hacia una modelización de la producción de bellota en encinares (*Quercus ilex* ballota). (2004) E. *Cuadernos de la Sociedad Española de Ciencias Forestales*. Núm. 18, p. 29-33.

TSAP-Time Series Analysis and Presentation, Version 4.0. Reference Manual, Frank Rinn, Heidelberg, Germany (1996).

Vanclay J.K. (1994) Modelling forest growth and yield applications to mixed tropical forests. CAB International, Wallingford, UK

Vasilakos C., Kalabokidis K., Hatzopoulos J. y I. Matsinos, 2009. Identifying wildland fire ignition factors through sensitivity analysis of a neural network. *Natural Hazards*. Vol. 50, p. 125-143.

Vázquez Piqué J., Tapias Martín R., Gutiérrez-Estrada J.C. y Pulido-Calvo I. (2007) Aproximaciones neuronales para la modelización del crecimiento diario del alcornoque (*Quercus suber* L.) en una dehesa del suroeste de España (Hinojos, Huelva). *Cuadernos de la Sociedad Española de Ciencias Forestales*, Vol. 23, p. 251-256.

Vázquez Piqué J. y Pereira H. (2004) Modelos de crecimiento en diámetro para alcornocales del centro y sur de Portugal. *Cuadernos de la Sociedad Española de Ciencias Forestales*. Vol. 18, p. 219-226.

Vega-García C. y Chuvieco E. (2006) Applying local measures of spatial heterogeneity to Landsat-TM images for predicting wildfire occurrence in Mediterranean landscapes. *Landscape Ecology*. Núm. 21, p. 595–605.

Vericat P., Piqué M. y Serrada R. (2012) Gestión adaptativa al cambio global en masas de *Quercus* mediterráneas. Lleida: *Centre Tecnològic Forestal de Catalunya*. 172 p.

World Wildlife Fund (2014). *WWF International*. [Citado 2014/jul/21]. <http://www.worldwildlife.org/>

Zhang Q.B., Hebda R.J. y Zhang Q.J. y Alfaro R.I. (2000) Modeling tree-ring growth responses to climatic variables using artificial neural networks. *Forest Science*. Vol. 46, p. 229-239.