

Evaluación de la influencia de la heterogeneidad de los bosques mediterráneos en la estimación de biomasa residual a partir de imágenes Landsat

García-Martín· Alberto^{1 a}; De la Riva, Juan^a; Pérez-Cabello, Fernando^a; Montorio, Raquel^a

^(a) Departamento de Geografía y Ordenación del Territorio, Facultad de Filosofía y Letras, Universidad de Zaragoza, C/ Pedro Cerbuna 12, 50009, Zaragoza, España.

RESUMEN

Se evalúa la influencia de la heterogeneidad –característica de los medios mediterráneos que dificulta la estimación de parámetros forestales con teledetección– en el ajuste de regresiones logísticas para la estimación de la biomasa residual de los bosques de pináceas de Teruel a partir de imágenes Landsat y variables auxiliares derivadas del MDE y del Mapa Forestal. Se calcula el CV de Pearson sobre las bandas reflectivas mediante una ventana de 3x3 centrada sobre 482 parcelas del Inventario Forestal (IFN-2). Se calculan diferentes modelos en función del grado de heterogeneidad.

Palabras claves: heterogeneidad forestal, biomasa residual forestal, Landsat TM.

ABSTRACT

This paper evaluates the influence of heterogeneity –Mediterranean forest characteristic which induces difficulty on forest parameters estimation using remote sensing– in the performance of logistic regressions to estimate residual biomass using Landsat TM images and ancillary data (DEM and forest map) in the pine forest of Teruel. The Pearson's coefficient of variation (CV) was calculated in the six spectral reflectance TM bands applying a 3x3 pixel window centred at each of the 482 plots of the 2nd Spanish Forest Inventory. Several models according to the degree of heterogeneity were performed.

Keywords: forest heterogeneity, forest residual biomass, Landsat TM.

Introducción

La biomasa residual forestal (BRF) refiere a las ramas, hojas, acículas y despuntes generados tanto en los tratamientos aplicados a las masas para su defensa y mejora, como a los generados en aprovechamientos madereros (IDAE, 1999; Velázquez, 2006). Los tratamientos más comúnmente aplicados a estos residuos son la quema controlada o el amontonamiento en el monte, siendo pocas veces triturados o astillados para favorecer su rápida incorporación al horizonte orgánico (Velázquez, 2006).

Tanto la Comisión Europea (CCE, 1997) como el Estado español (IDAE, 1999; IDAE, 2005), contemplan el aprovechamiento de los residuos forestales como una de las fuentes de biomasa

que pueden contribuir a cumplir los objetivos en producción de energía renovable. Los beneficios obtenidos son tanto ambientales (menor riesgo de incendios y plagas...), como socio-económicos (menor dependencia energética, dinamización local de la actividad económica). Pero su utilización como fuente de energía ha crecido más lentamente que otras (Domínguez *et al.*, 2003), debido principalmente al desconocimiento de la capacidad real de producción de BRF de las masas, lo que exige el desarrollo de metodologías de estimación.

La extracción de información biofísica es una de las líneas más fructíferas de las aplicaciones forestales de la teledetección (Bergen *et al.*,

¹ Contacto autor: Te: +34 976 761000 ext. 3909 Fax: +34 976 761506

Correo electrónico: algarcia@unizar.es

Copyright: Universidad Nacional del Centro de la provincia de Buenos Aires, Argentina.

2000), siendo numerosos los trabajos orientados a estimar LAI y biomasa, principalmente con datos Landsat (p.e.: Eklundh *et al.*, 2003; Lu *et al.*, 2004; Zheng *et al.*, 2004; Lu, 2006). Pero los ámbitos de aplicación han sido, en su mayoría, bosques boreales densos, homogéneos y de topografía simple, siendo pocas las experiencias en ámbitos mediterráneos. Las características intrínsecas de éstos (estructura abierta, fragmentación, presencia de otros elementos de paisaje, topografía irregular...) hacen que parcelas con una misma cantidad de biomasa puedan presentar alta variabilidad espectral, dificultando el ajuste de los modelos (Salvador y Pons, 1998a, 1998b; Mallinis *et al.*, 2004).

Aunque la biomasa no puede ser medida directamente mediante imágenes de satélite, la reflectividad puede relacionarse con la biomasa estimada a partir de trabajo de campo (Dong *et al.*, 2003); este principio se puede aplicar a la BRF. Aunque no existe información detallada sobre la BRF en España, mediante ecuaciones alométricas que relacionan la BRF de cada pie arbóreo con su diámetro normal (DBH) y su altura ha sido posible estimarla (V. Alonso *et al.*, 2005).

El objetivo de este trabajo es evaluar la influencia que tiene la heterogeneidad de los bosques mediterráneos en el ajuste de modelos de regresión logística que permitan localizar y estimar la BRF de los bosques turolenses de pináceas. Para ello, se utilizan datos de BRF obtenidos mediante ecuaciones aplicadas a las parcelas del *Segundo Inventario Forestal Nacional* (IFN-2) (MMA, 1996), como variable dependiente, y los registros de una imagen Landsat TM, de variables topográficas y de otras derivadas del *Mapa Forestal de Aragón*, como independientes. Para determinar los umbrales de heterogeneidad se utiliza el coeficiente de variación de Pearson (CV) calculado sobre los registros radiométricos para cada parcela.

Área de estudio

La provincia de Teruel (14.804 km²) se sitúa en el cuadrante NE de la Península Ibérica, dentro de la Región biogeográfica Mediterránea y con una superficie catalogada como forestal del 27%. La mayor parte de la riqueza forestal se concentra en las sierras ibéricas; las pináceas ocupan una superficie destacada: 235.431 ha con alguna de las especies seleccionadas como dominante. El carácter de provincia despoblada y envejecida, con marcado carácter agrario y escaso desarrollo del sector industrial y de servicios, convierte esta área en ámbito idóneo para

propiciar el efecto dinamizador que el aprovechamiento de BRF puede tener.

Metodología y materiales

Los métodos estadísticos empleados son el CV, para el análisis de la heterogeneidad de las parcelas del IFN-2, y la regresión logística, para espacializar la probabilidad de existencia de BRF a partir de umbrales de homogeneidad fijados con CV. Los programas utilizados son: Erdas 8.7, ArcGis 8.3 y SPSS 12.0.

Estimación de la BRF en parcelas del IFN-2

La BRF (Ton/ha) de *Pinus sylvestris*, *P. halepensis*, *P. nigra* y *P. pinaster* fue calculada para las parcelas del IFN-2 en las que todos los pies eran de una de estas especies. Son parcelas de forma circular con radio variable de 5 a 25 m en función del DBH de los pies muestreados; se consideran sólo los de DBH >7,5 cm. El cálculo se hizo mediante regresiones obtenidas con trabajo de campo, que consistió en un muestreo estratificado por especies, siendo la distribución del muestreo proporcional a la información de número de pies, volumen de leñas y área basimétrica mostrada en el IFN-2, con un rango para cada especie de 7,5 a 40 cm de DBH. Se obtuvo el peso en húmedo de la biomasa residual de cada individuo y se midió el DBH y la altura. Dada la variación en humedad de las muestras, de cada pie se prospectaron ramas y acículas para obtener el peso en seco, utilizando el método de secado a 105° C hasta pesada constante. Las ecuaciones para cada especie arrojaron un R² >0,90 (Alonso *et al.*, 2005).

Obtenida la información de BRF para cada parcela, ésta se añadió a una tabla junto a todas las variables recogidas en el IFN-2, incluyéndose la localización UTM. Para evitar la mezcla de signaturas espectrales de distintas especies sólo fueron seleccionadas las monoespecíficas. Se generó una cartografía puntual de 482 parcelas que fue superpuesta a la imagen Landsat.

Tratamiento de la imagen Landsat 5 utilizada

Se utilizó una imagen Landsat 5 TM de 29 de junio de 1994, sincrónica a los trabajos de campo del IFN-2 en la provincia de Teruel. Se aplicó una rigurosa corrección geométrica, a partir de 125 puntos tomados sobre un mosaico de ortomágenes de 1 m de resolución y un MDE de 25 m; se ajustó un polinomio de 2º grado (RMS <1 píxel); se optó por el método del vecino más próximo en la fase de transferencia.

Tras probar varios modelos de corrección radiométrica para conocer cuál minimizaba mejor

el efecto de la topografía, se optó por la corrección de Minnaert incluyendo el coseno de la pendiente como término separado en la ecuación (Colby, 1991), utilizando información preestratificada de la vegetación para calcular el coef. K para cada banda y tipo de superficie.

Se aplicaron diversas transformaciones a los valores de reflectividad (TM1, TM2, TM3, TM4, TM5, TM7): Componentes Principales (PC1, PC2, PC3), Transformación *Tasseled-Cap* (TC1, TC2, TC3), índices (NDVI, SAVI, OSAVI, GESAVI, GI, MSI), MID57 y Albedo (ABD).

Variables topográficas derivadas del MDE

Se calcularon las coberturas topográficas de elevación (ELV), pendiente (PEN), orientación (ORI), insolación potencial anual (INS_pot), insolación potencial en los equinoccios (PRI_pot, OTO_pot) y en los solsticios (VER_pot, INV_pot) y curvatura (CRV). La insolación se calculó tanto en función de la iluminación total como del número de horas (_hs). Todas se incorporaron como variables continuas excepto ORI, que fue reclasificada (NO, N y NE = 0; SE, S y SO = 1).

Variables del Mapa Forestal 1:50.000

La influencia de la estructura y de la fisonomía-fisiología de las masas forestales se consideró a partir del tipo climático estructural (TCE) y el nivel de madurez (NM), obtenidos del *Mapa Forestal de Aragón*. Las tres categorías TCE presentes en la zona fueron reclasificadas en dos grupos: Esclerófilo y Subsclerófilo, clase 0; Taiga, clase 1. Los tipos existentes de NM se agruparon también en dos: inferior al estadio 6, tipo 0; niveles 6 y 7, tipo 1.

Evaluación de la heterogeneidad

A las anteriores variables se superpuso la cartografía puntual estimada de BRF, a partir de una ventana de 3x3 píxeles, calculándose la media y la desviación estándar de cada variable.

La heterogeneidad de los bosques mediterráneos se traduce en una elevada variabilidad espectral relacionada con la presencia de otros elementos del paisaje (p.e. cortafuegos, pistas...), su localización en el borde de otra cubierta, la alta variabilidad interna o errores de localización de la parcela.

Siguiendo a Labrecque *et al.* (2003), la variabilidad espectral de cada parcela fue calculada utilizando el CV de Pearson:

$$CV = \frac{S}{|\bar{X}|}$$

donde S es la desviación estándar y X la media en la ventana de 3x3 píxeles.

Para determinar la influencia que tiene la heterogeneidad del entorno radiométrico en el ajuste de modelos de estimación se definieron 10 grupos de parcelas utilizando los CV obtenidos en cada banda; así, en cada grupo hay un número menor de parcelas, con entorno radiométrico más homogéneo. Se calcularon primero los umbrales de CV que permitían la separación de las parcelas en 10 percentiles; con posterioridad, esos umbrales sirvieron para la delimitación de los grupos: el primero incluye todas, el segundo aquellas con CV inferiores a los valores del percentil 9 en todas las bandas, el tercero aquellas cuyos CV estaban por debajo de los valores de CV del percentil 8 y así sucesivamente hasta 10 grupos. El análisis, para cada grupo, de la correlación entre BRF y las variables independientes permite determinar cómo influye la heterogeneidad del entorno radiométrico en el ajuste de los modelos.

La estimación mediante regresión logística

La regresión logística es un tipo especial de regresión utilizada para estimar la probabilidad de ocurrencia de una variable dependiente categórica binaria, permitiendo la entrada de variables continuas y/o categóricas sin que tengan que cumplir el supuesto de normalidad, siempre que no estén altamente correlacionadas entre sí. Los coeficientes indican la influencia relativa de las variables predictoras. La bondad de los ajustes puede ser evaluada en términos de porcentaje de la varianza explicada, lo que permite una mejor comprensión de la magnitud y el sentido interpretativo de cada variable.

El ajuste global de los modelos se evaluó mediante la R^2 de Nagelkerque, el test de Hosmer-Lemeshow y el grado de acierto en la tabla de clasificación. La significación de las variables dependientes se valoró con el estadístico Wald y su significación estadística (p -value <0,05).

Se aplicó la regresión logística por «pasos hacia delante» (*Forward stepwise approach*) incluyéndose –una a una– las variables con significación estadística (p -value <0,05). La variable dependiente fue categorizada en tres grupos, asignando 0 al inferior y 1 al más alto.

La muestra se dividió aleatoriamente en dos partes: 20% se reservó para validar, 80% se utilizó para ajustar el modelo. Para valorar la robustez de éste, la división de la muestra al azar se realizó cinco veces; la repetición de las va-

riables, la similitud de los coeficientes y el grado de acierto en la tabla de clasificación indican la independencia de la selección aleatoria. Se analizó también la auto-correlación de las variables, desechando aquellas >0,400.

Resultados

Determinación de los modelos de regresión

Los coeficientes de correlación (r de Pearson) obtenidos al relacionar BRF con las variables radiométricas indican que las correlaciones son mayores a medida que los grupos contienen parcelas con variabilidad espectral menor (Tabla 1), significativas con la gran mayoría de las variables (p -value <0,01).

Los mejores r de Pearson, en todos los grupos, se obtienen con variables que ofrecen información sobre humedad (TM5, TM7, CP3, TC3, MSI, MID57) y con algunos de los índices de vegetación (NDVI, SAVI, OSAVI, MSAVI). Con correlaciones algo inferiores en casi todos los grupos aparecen las tres bandas del visible, CP1, TC1 y TC2, los índices de vegetación GI y GESAVI y ABD; las peor correlacionadas son TM4 (su correlación deja de ser significativa a partir del grupo del percentil 5) y CP2 (con significación sólo en el grupo del percentil 5).

Respecto del signo de las correlaciones, la BRF presenta relación inversa con las bandas reflectivas. Llama la atención el caso de TM2 y, en especial, de TM4; sin embargo, tal y como señalan Mallinis *et al.* (2004), en bosques mediterráneos de estructura abierta esta relación inversa puede relacionarse con la alta influencia del suelo en la reflectividad. Las correlaciones son también inversas con las relacionadas con el brillo (PC1, TC1 y ABD) y con MSI y MID57, relacionados inversamente con la humedad. Por el contrario, la relación es positiva con TC2, PC3 y TC3 y con todos los índices de vegetación.

Respecto de la correlación con las topográficas, sólo seis son significativas para el grupo que incluye todas las parcelas: ELV, VER_pot_hs e INV_pot con p -value <0,01; INS_pot, PRI_pot y OTO_pot, con p -value <0,05. En el grupo del percentil 9, sólo las tres primeras mantienen una relación significativa con p -value <0,05 y en el percentil 8 sólo ELV y VER_pot_hs superan el test. El análisis de los signos revela que BRF tiene una relación positiva con ELV y VER_pot_hs y negativa con INV_pot.

Tabla 1. Coeficientes r de Pearson entre la BRF y las variables independientes.

	Percent 10	Percent 7	Percent 4
Nº Parcelas	482	208	68
TM1	-0,435*	-0,529*	-0,542*
TM2	-0,409*	-0,484*	-0,495*
TM3	-0,413*	-0,492*	-0,512*
TM4	-0,199*	-0,189*	-0,213
TM5	-0,451*	-0,552*	-0,641*
TM7	-0,452*	-0,562*	-0,639*
PC1	-0,429*	-0,509*	-0,560*
PC2	-0,032	-0,087	-0,115
PC3	0,421*	0,590*	0,754*
TC1	-0,414*	-0,483*	-0,521*
TC2	0,310*	0,436*	0,546*
TC3	0,453*	0,603*	0,750*
NDVI	0,457*	0,587*	0,684*
SAVI	0,455*	0,585*	0,682*
MSAVI	0,448*	0,578*	0,669*
OSAVI	0,457*	0,587*	0,683*
GESAVI	0,410*	0,529*	0,635*
GI	0,307*	0,448*	0,655*
MSI	-0,458*	-0,618*	-0,772*
MID57	-0,454*	-0,558*	-0,641*
ABD	-0,430*	-0,509*	-0,551*
ELV	0,158*	0,136	0,004
PEN	-0,085	-0,041	0,008
INS_pot_hs	0,072	0,056	0,064
INS_pot	-0,090..	-0,081	-0,061
PRI_pot_hs	0,071	0,067	0,012
PRI_pot	-0,094..	-0,085	-0,070
VER_pot_hs	0,162*	0,120	0,154
VER_pot	0,079	0,023	0,065
OTO_pot_hs	0,071	0,067	0,012
OTO_pot	-0,094..	-0,085	-0,070
INV_pot_hs	-0,003	-0,027	0,003
INV_pot	-0,120*	-0,091	-0,071
CRV	0,035	-0,016	0,143

.. Correlación significativa al nivel 0,05

* Correlación significativa al nivel 0,01

Explicación de las abreviaturas en el texto.

Se desprende que las radiométricas son más útiles para ajustar modelos de regresión logística; pero las topográficas que resultan significativas pueden ser incluidas en el ajuste de modelos de los grupos en que aparecen.

Como el análisis de las auto-correlaciones entre las variables radiométricas muestra que, en general, éstas son muy altas, se seleccionó la más correlacionada con la BRF del grupo para el ajuste, analizando si existían otras correlacionadas con BRF que lo estuvieran poco con la escogida en primer lugar.

Para evitar ajustar un modelo para cada grupo se estudió si era posible definir clústeres con estos grupos que presentaran situaciones simi-

lares. Para delimitarlos se consideró la variable independiente mejor correlacionada en más grupos, ya que ésta es la que más relación presen-

ta con la BRF con independencia de la homogeneidad de la muestra. Esta variable resultó ser MSI, con el mejor coeficiente r en 7 de los 9 grupos con correlación significativa.

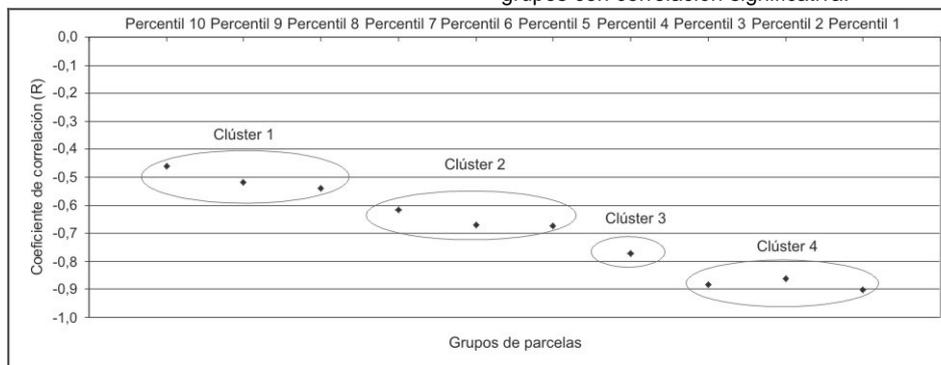


Fig. 1. Clústeres de agrupación de grupos delimitados sobre el gráfico de correlaciones entre MSI y BRF para cada grupo de parcelas.

A partir de las correlaciones entre MSI y BRF para cada grupo se delimitaron clústeres de grupos de parcelas con similar grado de heterogeneidad y valor de correlación (Fig. 1). El 1^{er} clúster contiene los grupos de percentiles 10, 9 y 8, que tienen en común el gran número de parcelas y el bajo r de Pearson. El 2^o clúster engloba los grupos 7, 6 y 5, de tamaño muestral semejante y r de Pearson intermedios. El 3^{er} clúster – grupo del percentil 4– representa una muestra de parcelas muy homogénea, pero con número suficiente para establecer un modelo predictivo, y un r alto. El 4^o clúster incluye los grupos de percentiles 3, 2 y 1, con parcelas más homogéneas, aunque su número es *a priori* pequeño para establecer modelos válidos. Se calculó un modelo de regresión para cada clúster con objeto de estudiar la influencia del grado de homogeneidad de la muestra y su tamaño en la calidad de la estimación.

Los modelos de regresión logística

Modelo de regresión logística del 1^{er} clúster

El grupo de percentil 10, con mayor número de parcelas (482), permite constatar la viabilidad de evaluar la BRF sin eliminar los problemas de heterogeneidad radiométrica.

La variable MSI es la más correlacionada con la dependiente, siendo seleccionada en primer lugar para formar parte del modelo. En el análisis de correlaciones parciales de MSI con el resto de radiométricas se detectó que no presentaba correlación alguna con TM4 (0,076), pero sí con las restantes (>0,400). En cuanto a la correlación de MSI y TM4 con las topográficas signifi-

cativas en su relación con BRF, todas ellas muestran correlaciones por debajo del umbral, por lo que pueden ser utilizadas en el modelo. También se introdujeron ORI, TCE y NM.

Determinadas las independientes, se dividió la variable BRF en tres grupos iguales. El valor de corte para definir el inferior (grupo 0) fue 7,488 Ton/ha; el valor para el grupo mayor (grupo 1) fue 18,865 Ton/ha; el grupo intermedio se eliminó, quedando 322 parcelas. Se calcularon 5 modelos, con distinta división aleatoria de la muestra en 2 grupos: 80% para el cálculo y 20% para la validación.

Los modelos seleccionaron tres variables: MSI, TM4 y NM. La incorporación de TCE mejora levemente –en un caso– las estadísticas, pero con escaso aporte explicativo, lo que se relaciona con una selección azarosa de las parcelas para el ajuste. Los otros 4 incorporan MSI, TM4 y NM, ajustando adecuadamente los datos según el test de Hosmer-Lemeshow, pues todos superan claramente el mínimo requerido (p -value >0,05). Las R^2 de Nagelkerque oscilan entre 0,429 y 0,473 y el acierto en la tabla de clasificación entre 77,8% y 79,4%.

Tabla 2. Variables incluidas en los modelos por clúster, β , error estándar, estadístico Wald, significación estadística y $Exp(\beta)$.

	Var.	β	S.E.	Wald	Sig.	$Exp(\beta)$
1	MSI	-6,38	0,99	40,84	0,000	0,002
	TM4	-0,22	0,05	16,49	0,000	0,802
	NM	1,07	0,31	11,48	0,001	2,910
	Cte.	9,87	1,54	40,82	0,000	19412,96
2	MSI	-9,31	1,92	23,49	0,000	0,000
	NM	1,34	0,56	5,74	0,017	3,835
	Cte.	8,00	1,86	18,43	0,000	2990,94
3	MSI	-17,69	5,64	9,83	0,002	0,000
	cons	17,49	5,68	9,47	0,002	3,91E+07
4	MSI	-19,27	12,09	2,54	0,111	0,000
	Cte.	18,99	12,60	2,27	0,132	1,78E+08

β y $Exp(\beta)$ permiten conocer la contribución que cada variable tiene en el ajuste del modelo (Tabla 2). Se observa cómo MSI y NM tienen una mayor importancia, con $Exp(\beta)$ más alejados del valor 1 (0,002 y 2,910, respectivamente); por el contrario, TM4 es poco importante ($Exp(\beta)$ de 0,802). El signo de β ayuda en la interpretación física de cada variable: MSI está relacionada de forma inversa con el contenido de humedad; el signo negativo indica que a mayor humedad de la masa forestal (menor valor de MSI), mayor cantidad de BRF.

El signo negativo de TM4 indica que a mayor reflectividad menor es la cantidad de BRF, en relación con la estructura abierta de los bosques mediterráneos. Así, TM4 es complementaria de MSI e indica la existencia de parcelas heterogéneas típicas de estos ambientes.

El carácter positivo de β para la variable NM indica que las pináceas del nivel de madurez 6 y 7 tienen más BRF que las de niveles inferiores, resultado coherente ya que los bosques que presentan mejor adaptación a las condiciones del medio con un mejor aprovechamiento de la potencialidad natural son las que producen mayor cantidad de BRF.

Para la validación del modelo se utilizó el estadístico *Kappa* con la muestra reservada del 20%; los resultados varían entre 0,539 y 0,638.

Modelo de regresión logística del 2º clúster

El mayor tamaño muestral es también el motivo de la elección del percentil 7 para el 2º clúster. Compuesto por 208 parcelas, es presumible la validez del resultado obtenido para ajustar un modelo adecuado para toda el área de estudio. Como en el caso anterior, MSI es la variable más correlacionada. De nuevo, TM4 es la única variable correlacionada con la biomasa y no con MSI. Como ninguna de las variables topográficas ofrecía correlaciones significativas con la dependiente, sólo se añadieron a las radiométricas ORI, TCE

y NM. El umbral de corte para definir el grupo 0 fue 7,284 Ton/ha, 18,213 Ton/ha para el grupo 1.

Los cinco modelos ajustados seleccionaron las variables MSI y NM, todos ellos significativos al nivel de $p < 0,05$, superando ampliamente el Test de Hosmer-Lemeshow. Los R^2 de Nagelkerke son superiores a los del anterior grupo y varían entre 0,574 y 0,605. El grado de acierto en la tabla de clasificación superó en todos ellos el 80%. El *Kappa* obtenido con la muestra de validación superó en cuatro de los cinco modelos el valor máximo obtenido considerando todas las parcelas (0,638).

Los β de MSI y NM mantienen el mismo signo que los modelos que utilizaban todas las parcelas, por lo que la explicación física del modelo es la misma (Tabla 2). $Exp(\beta)$ indica que ambas variables son importantes en el modelo.

A partir de las variables seleccionadas y sus respectivos β se ha cartografiado la probabilidad de biomasa forestal residual (Fig. 2). En esta cartografía, el valor de cada píxel oscila entre 0 y 1, siendo 0,5 el umbral de probabilidad que determina si un píxel pertenece al grupo 1 ($e \gg 18,865$ Ton/ha) o al grupo 0 ($d \gg 7,488$ Ton/ha).

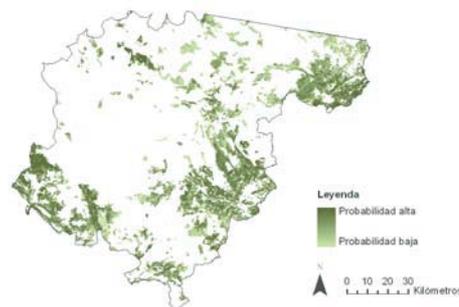


Fig. 2. Probabilidad de existencia de BRF con respecto a los umbrales de corte definidos en el modelo del 2º clúster.

El modelo de regresión logística del 3º clúster

Este modelo utiliza las 68 parcelas del grupo del percentil 4, manifestando una elevada homogeneidad, aunque el pequeño número de parcelas puede hacer que esté sobre ajustado. MSI es también la variable radiométrica más correlacionada. No se encontró ninguna otra radiométrica correlacionada con la BRF que lo estuviera poco con MSI; por ello –y por la inexistencia de correlaciones con las variables topográficas– sólo MSI y las tres variables categóricas son tenidas en cuenta. Los umbrales para delimitar los grupos 0 y 1 de BRF fueron 6,295 y 17,521 Ton/ha, respectivamente.

La única variable incluida fue MSI, resultando todos los modelos significativos al nivel de

$p < 0,05$. Los valores de Hosmer-Lemeshow indican que los datos han sido ajustados correctamente (p -values $> 0,700$). Los R^2 de Nagelkerque ascienden a valores $> 0,700$; el acierto en las tablas de clasificación oscila entre 88,9 y 90,5%; el estadístico *Kappa* de la validación alcanza valor 1 en las cinco pruebas.

El modelo de regresión logística del 4º clúster

El modelo del grupo del percentil 3 es el máximo exponente de homogeneidad; pero la escasez de la muestra (36 parcelas) indica que el resultado obtenido no podrá ser generalizable a todo el área de estudio. El objetivo de su cálculo es comprobar cómo la variable principal seleccionada (MSI) sigue siendo válida cuando no existen dudas de la pureza de la muestra. Los valores de corte para definir los grupos 0 y 1 fueron 5,494 y 21,606 Ton/ha, respectivamente. MSI fue la única variable incluida en todos los modelos, siempre significativos al nivel de $p < 0,05$, los valores de Hosmer-Lemeshow son también muy superiores a este valor. Los R^2 de Nagelkerque son muy altos, entre 0,754 y 0,898.

Pese a estos buenos datos globales, dos de los cinco modelos ajustados no son válidos ya que los estadísticos de significación de MSI y de la constante indican que su significación está por encima del nivel de $p < 0,05$ (Tabla 2); además, el *Kappa* es no significativo en un caso.

Discusión

La consideración de distintos grupos de parcelas en función de su heterogeneidad radiométrica ha permitido modelar la influencia que el carácter heterogéneo de los bosques mediterráneos tiene en el ajuste de modelos estimativos de variables forestales continuas. Así, tal y como se observa en los coeficientes r obtenidos, éstos son más altos conforme las parcelas consideradas para el análisis presentan entornos radiométricos más homogéneos.

Del conjunto de variables radiométricas consideradas, MSI destaca como la más útil para estimar BRF. La identificación de una variable relacionada con la humedad como mejor predictor es acorde con trabajos que han abordado la estimación de biomasa o LAI (Eklundh *et al.*, 2003; Lu *et al.*, 2004).

La aportación de las variables topográficas es escasa, pues sólo algunas (principalmente ELV, VER_pot_hs e INV_pot) arrojan correlación significativa en los tres grupos con mayor número de parcelas, desapareciendo la significación cuando sólo se consideran las más homó-

géneas. El análisis de correlaciones efectuado con todas las parcelas ya señalaba que las radiométricas eran las que mejor podían estimar BRF; finalmente, ningún modelo incorporó estas variables. Por el contrario, una de las categorías derivadas del Mapa Forestal entró en dos modelos.

En cuanto a los modelos de regresión logística ajustados para los distintos clústeres, el R^2 de Nagelkerque obtenido en el modelo del 1º clúster indica que existe una gran cantidad de varianza de la variable dependiente por explicar, que está relacionada con la alta heterogeneidad de estos bosques y con imprecisiones en el tratamiento de los datos y en la localización de los puntos del IFN-2. La eliminación de las parcelas más heterogéneas en el 2º clúster mejora las medidas de ajuste global, siendo este modelo más adecuado que el anterior. Lo mismo sucede en el 3º clúster; sin embargo, el escaso número de parcelas para calcularlo y el que sean altamente homogéneas hace que el modelo pueda no ser representativo para todos los bosques, dado que la heterogeneidad es una de sus características intrínsecas.

Conclusiones

Se ha mostrado la validez de las imágenes Landsat TM –junto a variables derivadas de un MDE y de cartografía forestal– para desarrollar una metodología que permita evaluar BRF.

El coeficiente de variación de Pearson se ha revelado como técnica adecuada para modelar y conocer el grado de heterogeneidad del entorno de las parcelas del IFN-2, permitiendo ajustar modelos para distintos supuestos: considerando que todas son válidas para la regresión; eliminando las que pueden presentar errores de localización y/o incluyen otros elementos del paisaje que introducen heterogeneidad; y, finalmente, incluyendo sólo las más homogéneas.

La regresión logística se ha mostrado como una herramienta eficaz para cartografiar zonas con alta y baja probabilidad de BRF a partir de la consideración de variables continuas y categóricas sencillas de obtener a partir del uso de técnicas de teledetección y SIG.

Aunque los mejores ajustes se consiguen con las parcelas más homogéneas, el carácter heterogéneo de los bosques mediterráneos sugiere que el modelo más adecuado para el área de estudio es el que sólo elimina las parcelas que más claramente presentan problemas de localización o que incluyen otros elementos paisajísticos; tal es el caso del modelo del 2º clúster, que conserva gran parte de la muestra inicial (208 parcelas).

Es necesario señalar que estos métodos de ajuste presentan el inconveniente de su carácter local. Además, conviene incidir en la necesidad de encontrar modelos que permitan cuantificar de forma más precisa la cantidad de BRF. Parece necesario seguir explorando la capacidad predictiva de las imágenes de satélite y de las variables topográficas y forestales mediante su inserción en modelos de regresión multivariantes.

Agradecimientos

Este trabajo ha sido financiado por una beca FPU del MEC (AP2003-3097) y ha contado con el apoyo de los proyectos LIGNOSTRUM (AGL2002-03917-AGR-FOR), RS_FIRE y PIR_FIRE (CGL2005-04863/CLI, PIP098/2005).

Referencias

- Alonso, E., Asín, J., Pascual, J. 2005. Biomasa residual forestal: regresiones para las especies del género *Pinus* existentes en la provincia de Teruel. En Sociedad Española de Ciencias Forestales (Ed.), La ciencia forestal: respuestas para la sostenibilidad. Zaragoza, SECF (CD-Rom).
- Bergen, K., Colwell, J., Sapio, F. 2000. Remote sensing and forestry: collaborative implementation for a new century of forest information solutions. *Journal of Forestry*, 98 (6): 4-9.
- CCE. 1997. Energía para el Futuro: Fuentes de Energía Renovables. Libro Blanco para una Estrategia y un Plan de Acción Comunitarios. Comisión de las Comunidades Europeas.
- Colby, J.D. 1991. Topographic normalization in rugged terrain. *PE&RS*, 57: 531-537.
- Domínguez-Bravo, J., Ciria, P., Esteban, L.S., Sánchez, D., Lasry, P. 2003. Evaluación de la biomasa potencial como recurso energético en la región de Navarra (España). *Geo-Focus*, 3: 1-10.
- Dong, J., Kaufmann, R.K., Myneni, R.B., Tucker, C.J., Kauppi, P., Liski, J., Buermann, W., Alexeyev, V., Hughes, M.K. 2003. Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and links. *Remote Sensing of Environment*, 84: 393-410.
- Eklundh, L., Hall, K., Eriksson, H., Ardö, J., Pilesjö, P. 2003. Investigating the use of Landsat thematic mapper data for estimation of forest leaf area index in southern Sweden. *Canadian Journal of Remote Sensing*, 29 (3): 349-362.
- DAE 1999. Plan de fomento de las energías renovables en España. Madrid, Instituto para la Diversificación y Ahorro de la Energía, MEC.
- IDAE 2005. Plan de Energías Renovables en España 2005-2010. Madrid, Instituto para la Diversificación y Ahorro de la Energía, Ministerio de Industria, Turismo y Comercio.
- Labrecque, S., Fournier, R.A, Luther, J.E., Piercey, D.E. 2003. A comparison of three approaches to map forest biomass from Landsat-TM and inventory data in Western Newfoundland. *Proceedings of 25th Canadian Symposium on Remote Sensing*. Montreal.
- Lu, D. 2006. The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing* 27 (7): 1297-1328.
- Lu, D., Mausel, P., Brondizio, E., Moran, E. 2004. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. *Forest Ecology and Management*, 198: 149-167.
- Mallinis, G., Koutsias, N., Makras, A., Karteris, M. 2004. Forest parameters estimation in a European Mediterranean landscape using remotely sensed data. *Forest Science*, 50 (4): 450-460.
- MMA 1996. Segundo Inventario Forestal Nacional (1986-1995): Teruel. Madrid, MMA.
- Salvador, R., Pons, X. 1998a. On the applicability of Landsat TM images to Mediterranean forest inventories. *Forest Ecology and Management*, 104: 193-208.
- Salvador, R., Pons, X. 1998b. On the reliability of Landsat TM for estimating forest variables by regression techniques: a methodological analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 36: 1888-1897.
- Velázquez, B. 2006. Situación de los sistemas de aprovechamiento de los residuos forestales para su utilización energética. *Ecosistemas 2006* /1.
- Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J., Ryu, S.R. 2004. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sensing of Environment*, 93: 402-411.