

DEPARTAMENT DE FÍSICA DE LA TERRA I
TERMODINÀMICA

UNA METODOLOGÍA PARA LA ESTIMACIÓN DEL
RIESGO DE INCENDIO EMPLEANDO IMÁGENES DEL
SENSOR MODIS/TERRA.

MARIA DEL MAR BISQUERT PERLES

UNIVERSITAT DE VALÈNCIA
Servei de Publicacions
2011

Aquesta Tesi Doctoral va ser presentada a València el dia 13 de maig de 2011 davant un tribunal format per:

- Dr. César Coll Company
- Dr. Gerardo Pardo Sánchez
- Dra. Carmen Recondo González
- Dra. Raquel Niclòs Corts

Va ser dirigida per:

Dr. Juan Manuel Sánchez Tomás

Dr. Vicente Caselles Miralles

©Copyright: Servei de Publicacions
Maria del Mar Bisquert Perles

I.S.B.N.: 978-84-370-8227-1

Edita: Universitat de València
Servei de Publicacions
C/ Arts Gràfiques, 13 baix
46010 València
Spain
Telèfon:(0034)963864115

UNIVERSITAT DE VALÈNCIA

Facultat de Física

Departament de Física de la Terra i Termodinàmica



VNIVERSITAT
DE VALÈNCIA

**Una metodología para la estimación del riesgo
de incendio empleando imágenes del sensor
MODIS/TERRA**

Tesis Doctoral

MARIA DEL MAR BISQUERT PERLES

2011

D. JUAN MANUEL SÁNCHEZ TOMÁS, contratado Juan de la Cierva en el departamento de Física Aplicada de la Escuela de Ingenieros Industriales de Albacete de la Universidad de Castilla la Mancha, y

D. VICENTE CASELLES MIRALLES, Catedrático de Física Aplicada, adscrito al Departament de Física de la Terra i Termodinàmica de la Facultat de Física de la Universitat de València,

CERTIFICAN

Que la presente Memoria titulada “Una metodología para la estimación del riesgo de incendio empleando imágenes del sensor MODIS/TERRA”, ha sido realizada bajo su codirección en el Departament de Física de la Terra i Termodinàmica de la Universitat de València por Maria del Mar Bisquert Perles y constituye su Tesis Doctoral para optar al grado de Doctora en Física.

Y para que así conste, firmamos el presente certificado en Burjassot, a 14 de marzo de 2011

Fdo.: Juan Manuel Sánchez Tomás

Fdo.: Vicente Caselles Miralles

A mi familia

A Domingo

Deseo expresar aquí mi más sincero agradecimiento a las personas e instituciones cuya aportación y cooperación han hecho posible la realización de este trabajo.

En primer lugar a mis directores, el Dr. Juan Manuel Sánchez Tomás y el Profesor Vicente Caselles Miralles, quienes, además de ofrecerme la oportunidad de iniciarme en el mundo de la investigación, me han apoyado siempre para seguir adelante. Tengo que agradecerles también todo el tiempo que han dedicado a dirigir mi trabajo, así como la confianza que han depositado en mí.

A la Profesora Soledad Gandía Franco, Directora del Departamento de Física de la Tierra y Termodinámica, por estar siempre dispuesta a recibirme y aclarar todas mis dudas.

A los Profesores César Coll Company y Enric Valor i Micó por la acogida en el grupo y por las oportunidades que me han ofrecido.

Especialmente quisiera agradecer a mis padres, Anna y Juan, que siempre han confiado en mí y me han apoyado y animado siempre. En especial, en la decisión de iniciarme en la investigación, que les ilusionó igual o más que a mí. Sin su apoyo y cariño no habría llegado hasta aquí.

A Domingo, que me ha acompañado en esta etapa de mi vida y la ha llenado de felicidad. Gracias también a ti por apoyarme, animarme y escucharme siempre.

A Joan Miquel, Maria, Vicent, Carolina y Eduardo, con los que he compartido despacho. Gracias a todos por estar siempre dispuestos a ayudarme en lo que necesite. Gracias también por la alegría con que llenáis el despacho. Muy especialmente, gracias a Joan Miquel que me introdujo en el mundo de la programación, además de resolver un millón de dudas de cualquier tema y a Eduardo que colaboró conmigo utilizando redes neuronales.

A los componentes del grupo Thor: Inmaculada Paz Andrade, José Luís Legido, Eulogio Jiménez, Tarsy Carballas, Enrique Carballo, Marta Mato y Álvaro Gago por facilitarme los datos de incendios, por resolverme todas las dudas, por proponer

mejoras en el trabajo realizado, por confiar en mí y por acogerme durante unos meses. Gracias también a Azucena Varela que a pesar de no trabajar ya en la Universidad me ayudó a aclarar algunas dudas.

La realización de la presente memoria ha sido financiada por el Ministerio de Ciencia e Innovación (Proyectos CGL2007-64666/CLI, CGL2008-03668/CLI y contrato Juan de la Cierva de J.M. Sánchez) y la Generalitat Valenciana (Proyecto PROMETEO/2009/086).

Índice

1. La teledetección en la prevención de los incendios forestales.....	1
1.1. Los incendios forestales.....	3
1.2. Estado hídrico de la vegetación.....	4
1.3. Respuesta espectral de la vegetación	5
1.4. Índices de vegetación	7
1.5. Antecedentes.....	11
1.6. Objetivos de la Tesis	14
1.7. Estructura de la memoria	15
2. Variaciones de los índices de vegetación como indicadores del riesgo de incendio.....	17
2.1. Datos de incendios	19
2.2. Imágenes de satélite.....	20
2.2.1.Producto MOD13Q1	21
2.2.2.Producto MOD09A1.....	23
2.3. Procesado de las imágenes.....	25
2.4. Relación entre la frecuencia de los incendios y la variación de los índices espectrales.....	29
2.5. Resumen	30
3. Aplicación a las zonas de estudio	33
3.1. Zonas de estudio.....	35
3.2. Relaciones entre la frecuencia de incendios y los índices espectrales	38
3.3. Validación	41
3.4. Resumen	44

4. Estimación del riesgo de incendio a través de regresión logística	47
4.1. Regresión logística	49
4.1.1. Análisis de errores y bondad del ajuste	50
4.2. Aplicación de la regresión logística a la estimación del riesgo de incendio	51
4.2.1. Descripción	51
4.2.2. Resultados	52
4.3. Niveles de riesgo	57
4.4. Análisis de resultados por años	59
4.5. Resumen	62
5. Conclusiones	65
Bibliografía	69
Apéndice A: Bandas de MODIS	77
Apéndice B: Banda de calidad del producto MOD13Q1	81
Apéndice C: Banda de calidad del producto MOD09A1	85
Apéndice D: Artículo “Vegetation indices as fire risk indicators using MODIS images”	89
Apéndice E: Artículo “Fire danger estimation from MODIS Enhanced Vegetation Index data. Application to Galicia region (northwest Spain)”	111

Capítulo 1

La teledetección en la prevención de los incendios forestales

1.1. Los incendios forestales

Los sistemas de predicción de riesgo de incendios se están convirtiendo en una herramienta muy importante en la lucha contra los incendios forestales, debido especialmente al aumento del número de incendios, así como a la gravedad de éstos, en los últimos años. Según el Ministerio de Medio Ambiente (2006) que recoge las estadísticas de incendios de las últimas décadas, entre los años 1.961 y 1.977 el número de incendios anual en España era inferior a 5.000 y en muchos casos no pasaba de los 2.000. Sin embargo, desde el año 1.989 hasta el 2.005, el número de incendios anual ha sido siempre superior a 12.000, llegando hasta los 25.000 incendios en el año 2.005.

Los incendios forestales son altamente perjudiciales para el medio ambiente. Sus efectos más evidentes se centran en la vegetación, los suelos y la fauna; sin embargo, son también una fuente importante de emisión de CO₂ y de otros gases de efecto invernadero (González-Alonso et al., 1997). Además, al disminuir la proporción de vegetación tras un incendio aumenta la temperatura del suelo, dando lugar a cambios en el régimen de flujos energéticos en superficie. Este efecto es importante incluso años después del incendio, especialmente si la zona afectada es una zona de bosque (Sánchez et al., 2009). Además de todo esto, no hay que olvidar las pérdidas económicas, y por supuesto, en ocasiones las pérdidas humanas.

En vista del considerable aumento en el número de incendios y de la agresividad y severidad cada vez mayor de éstos, la investigación en la prevención de los incendios forestales es de vital importancia para la sociedad. Los sistemas que facilitan información de los lugares y fechas donde es más probable, o hay mayor peligro de que se produzca un incendio, es una herramienta muy útil para los organismos de lucha contra incendios forestales. Sin embargo, la gran mayoría de los incendios tienen como causa, ya sea voluntaria o accidental, la acción antropogénica, lo cual dificulta la obtención de este tipo de modelos de riesgo. En el periodo 1996-2005, en torno al 60% de los incendios en España fueron intencionados, cerca del 18% fueron por negligencias, un 2% fueron reproducciones, un 4% tuvieron como causa un rayo y un 17% fueron de causa desconocida (figura 1.1).




Figura 1.1. Número de incendios por grupo de causas.
Fuente: Ministerio de Medio Ambiente (2006).

1.2. Estado hídrico de la vegetación

El estado hídrico de la vegetación es un factor importante en la ignición de los bosques, por lo tanto es importante poder estimarlo e introducirlo como un parámetro más en los sistemas de predicción de incendios forestales.

Los dos indicadores más utilizados para la estimación directa del contenido en agua de las plantas son el *Fuel Moisture Content* (FMC) y el *Equivalent Water Thickness* (EWT) definidos en Maki et al. (2004) como:

- Fuel Moisture Content (FMC): relación entre la cantidad de agua en la vegetación y el peso de la vegetación seca.

$$FMC = \frac{FW - DW}{DW} \times 100 \quad (\%) \quad (1.1)$$

donde FW (fresh weight) es el peso de la vegetación medido en el campo y DW (dry weight) es el peso de la vegetación después de haber sido secada.

- Equivalent Water Thickness (EWT): relación entre la cantidad de agua y el área:

$$EWT = \frac{FW - DW}{A} \quad (\text{g/cm}^2) \quad (1.2)$$

donde A es el área foliar.

El método más exacto de estimación de la cantidad de agua en la vegetación es la medida directa, la cual implica la recogida de muestras de campo y el uso de métodos gravimétricos. Sin embargo, éste es un trabajo muy costoso en términos económicos y de tiempo. Una forma indirecta de medir el FMC es mediante el uso de índices meteorológicos, pero este método también presenta muchas dificultades ya que las estaciones meteorológicas son puntuales y no abarcan todo el territorio, aún así este método es útil para la estimación de la humedad de los combustibles muertos ya que, en este caso, su contenido en agua está muy relacionado con las condiciones atmosféricas (Yebra et al., 2008). En el caso de combustibles vivos, las distintas especies reaccionan de diferente forma ante las mismas condiciones atmosféricas, por lo que no se pueden utilizar estas variables para estimar el FMC (Yebra et al., 2008).

La teledetección se ha mostrado como una herramienta muy útil para la medida del estrés hídrico de la vegetación y se ha utilizado en numerosos estudios para la estimación del FMC (Yebra et al., 2008; Stow et al., 2005).

1.3. Respuesta espectral de la vegetación

El uso de la teledetección para estimar el estrés hídrico de la vegetación se basa en la diferente respuesta espectral de la vegetación para las distintas longitudes de onda en función del contenido en agua. La vegetación sana tiene una curva espectral característica como la que se muestra en la figura 1.2, con reflectividades bajas en el visible, altas en el IRC (infrarrojo cercano) y otra vez bajas (con presencia de máximos relativos) en el IRM (infrarrojo medio). Esta curva se puede ver alterada por distintos factores que afectarán de forma

diferente a las reflectividades de las distintas longitudes de onda. Los pigmentos de la hoja están relacionados principalmente con el intervalo visible del espectro. La estructura celular afecta al IRC, mientras que el contenido en agua se caracteriza mejor en la zona del IRM.

En el intervalo visible, los pigmentos de la hoja (clorofila, xantofila y caroteno) son absorbentes en torno a los 0,445 μm . La clorofila, además, presenta otra banda de absorción en torno a los 0,645 μm , quedando un máximo entre estas dos bandas, en los 0,55 μm , que es el responsable del color verde de las plantas.

En el infrarrojo cercano, las clorofilas son muy poco absorbentes y las cavidades de aire internas de la hoja (responsables de la respiración de las plantas) dispersan gran parte de la radiación incidente en este intervalo, dando lugar a las reflectividades más elevadas de la curva espectral de la hoja (Chuvienco, 2008). Cuando la hoja no está sana, la reflectividad en el IRC disminuye.

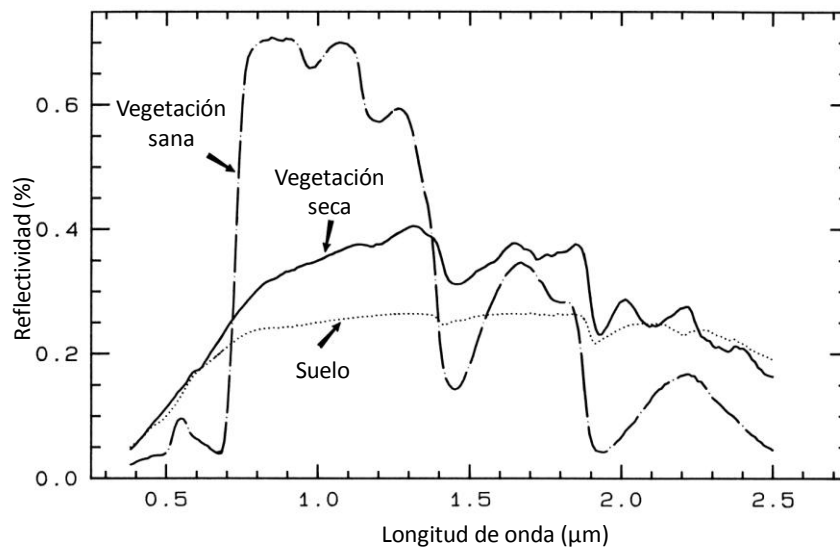


Figura 1.2. Curvas de reflectividad para la vegetación sana, la vegetación seca y el suelo desnudo.

En el infrarrojo medio el efecto predominante es la absorción del agua. La reflectividad del agua en el infrarrojo cercano y medio es muy baja, además se presentan unas bandas de absorción características. La presencia de agua en la vegetación provoca una disminución en la zona del infrarrojo medio, apreciándose significativamente las llamadas bandas de absorción del agua en torno a los 1,4 μm , 1,9 μm y 2,5 μm . Cuanto mayor sea la cantidad de agua en la hoja, menor será la reflectividad en esta zona del espectro y más apreciables serán las bandas de absorción (fig. 1.2). Sin embargo, además de los efectos directos del agua en el espectro de la vegetación, se observan efectos indirectos, ya que al disminuir la cantidad de agua en la planta la estructura de la hoja se ve afectada, provocando una disminución en el infrarrojo cercano y también en el verde.

1.4. Índices de vegetación

Se han definido numerosos índices espectrales, llamados índices de vegetación, que consisten en combinaciones de las reflectividades de distintas bandas para cuantificar la vegetación de una escena. Se definen con el fin de estudiar la vegetación de una escena con independencia de los factores perturbadores de la señal radiométrica como puede ser la reflectividad del suelo (Gilabert et al., 1997), mediante normalización de la influencia de estos factores. El índice de vegetación ideal fue descrito por Jackson et al. (1983) como “aquél particularmente sensible a la cubierta vegetal, insensible al brillo y color del suelo y poco afectado por la perturbación atmosférica, los factores medioambientales y las geometrías de la iluminación y de la observación”.

Generalmente, los índices de vegetación se basan en la diferencia entre la reflectividad en el rojo (R) y en el infrarrojo cercano (IRC). Si observamos la figura 1.2 vemos que efectivamente las diferencias más importantes entre la vegetación sana, la vegetación seca y el suelo aparecen en la zona del rojo centrada en los 0,645 μm y en la zona del infrarrojo cercano, entre 0,8 y 1,3 μm . La vegetación sana presenta un mínimo relativo en el rojo y un máximo absoluto en el infrarrojo cercano. En la vegetación seca no aparecen este mínimo y este máximo, sino que lo que se observa es una tendencia ascendente de la reflectividad desde el azul (B), centrado en los 0,445 μm , hasta los 1,3 μm , y a continuación los mínimos

relativos en las bandas de absorción del agua. La curva de reflectividad del suelo es similar a la de la vegetación seca pero con valores inferiores en la zona del infrarrojo y siendo los mínimos relacionados con la humedad menos significativos que en el caso de la vegetación.

Si se representa en un diagrama la reflectividad de un suelo sin vegetación en el infrarrojo cercano frente a la reflectividad en el rojo se obtiene que todos los puntos se distribuyen a lo largo de una línea recta (figura 1.3), esta línea se denomina *línea del suelo*. Los índices de vegetación se definen a partir de la línea del suelo. Cuando en ese suelo hay vegetación, la reflectividad en el infrarrojo cercano aumenta y en el rojo disminuye (punto A'). Los distintos índices de vegetación miden la distancia de los puntos con vegetación a la línea del suelo con distintas métricas (Gilabert et al., 1997).




Figura 1.3. Esquema de la línea del suelo. El punto A corresponde a suelo sin vegetación y el A' al mismo suelo con una cierta cantidad de vegetación.

El índice de vegetación más conocido y utilizado en el campo de la teledetección es el **NDVI** (Normalized Difference Vegetation Index), propuesto por Rouse et al. (1974) y definido como:

$$\text{NDVI} = \frac{IRC - R}{IRC + R} \quad (1.3)$$

Posteriormente se han definido numerosos índices de vegetación que incluyen parámetros para eliminar las contribuciones del suelo y de la atmósfera,

algunos incluyen otras bandas como la del azul y la del infrarrojo medio, que está más relacionada con el agua. A continuación se presentan los índices que se utilizan en esta Tesis y una pequeña descripción de éstos.

El **SAVI** (Soil Adjusted Vegetation Index) fue definido por Huete (1988) con el objetivo de minimizar las influencias del suelo. Se trata de una modificación del NDVI en la que se incluye un parámetro L que ha de ajustarse en función de la vegetación de la zona (ecuación 1.4). Se observa que en función del LAI (Leaf Area Index) hay unos valores de L para los que las diferencias en el índice SAVI con un suelo oscuro y claro son mínimas. Los valores óptimos que se encontraron son los siguientes: para una zona con baja densidad de vegetación se utiliza L=1, para una densidad media L=0,5 y para una densidad alta L=0,25.

$$\text{SAVI} = \frac{NIR - Red}{NIR + Red} \cdot \frac{L + 1}{L + \sqrt{L^2 + 1}} \quad (1.4)$$

Hardisky et al. (1983) comprobaron que una modificación del NDVI que consiste en sustituir la banda del infrarrojo cercano por la del infrarrojo medio, centrada en los 1,65 µm, (ecuación 1.5) permite estimar mejor la cantidad de agua de la vegetación. Este índice es el **NDII** (Normalized Difference Infrared Index).

$$\text{NDII} = \frac{NIR - SWIR}{NIR + SWIR} \quad (1.5)$$

Pinty & Verstraete (1992) definen un nuevo índice, **GEMI** (Global Environment Monitoring Index), basado en las bandas del rojo y del infrarrojo cercano, y diseñado específicamente para reducir las perturbaciones atmosféricas (ecuación 1.6).

$$\text{GEMI} = \frac{NIR - Red}{NIR + Red} \cdot \frac{NIR - SWIR}{NIR + SWIR} \quad (1.6)$$

En 1996, basándose en los nuevos satélites que se estaban construyendo con bandas más estrechas, Gao definió un nuevo índice para estimar el estado hídrico de la vegetación, el **NDWI** (Normalized Difference Water Index). Este índice (ecuación 1.7) incluye una banda del infrarrojo cercano (centrado en 0,86 µm) y otra del infrarrojo medio (centrado en 1,24 µm).

$$\text{NDWI} = \frac{NIR - SWIR}{NIR + SWIR} \quad (1.7)$$

Más recientemente Huete et al. (1999) diseñaron un índice específico para el sensor MODIS (MODerate resolution Imaging Spectroradiometer) que además de incluir las bandas del IRC y del rojo incluye una banda en el azul que permite reducir los efectos atmosféricos, y una serie de parámetros que limitan las contribuciones del suelo, se trata del **EVI** (Enhanced Vegetation Index) y lo definieron como:

$$\text{EVI} = \frac{G - C_1 R - C_2 B}{L + C_1 R + C_2 B} \quad (1.8)$$

donde G es un factor de ganancia, C_1 y C_2 son los coeficientes para limitar las influencias atmosféricas del rojo y L es la radiancia de fondo. Todos estos parámetros se determinan experimentalmente y toman los siguientes valores: $L=1$, $C_1=6$, $C_2=7,5$ y $G=2,5$.

Gitelson et al. (2002) definen un índice específico para las zonas de cultivo, el **VARI** (Visible Atmospherically Resistant Index), el cual incluye únicamente bandas del visible (ecuación 1.9), la razón de eliminar las bandas del infrarrojo es que se ha observado una fuerte dependencia de éstas con las especies vegetales, dando lugar en ocasiones a una disminución de la reflectividad en el infrarrojo cercano al aumentar la cubierta vegetal, esto está relacionado con la arquitectura de la planta, la inclinación de las hojas, la estructura celular, etc., mientras que la zona del visible no es tan dependiente de la especie en cuestión.

$$\text{VARI} = \frac{G - R}{G + R} \quad (1.9)$$

donde G es la banda del verde.

En Ceccato et al. (2002) se define un nuevo índice, **GVMi** (Global Vegetation Moisture Index), para optimizar la medida del contenido en agua de la vegetación y minimizar los efectos perturbadores atmosféricos y geofísicos (ecuación 1.10). Este índice fue definido basándose en las bandas del sensor SPOT-VEGETATION.

$$\text{GVMi} = \frac{G - R}{G + R} \quad (1.10)$$

1.5. Antecedentes

Se ha demostrado en distintos trabajos que existe una relación cuantificable entre el FMC y los índices de vegetación (Burgan et al., 1998; Maki et al., 2004; Chuvieco et al. 2004a; Stow et al., 2005; Cheng et al., 2006; Yebra et al., 2008). Además, los índices de vegetación o el FMC estimado a partir de índices de vegetación se han utilizado ya en algunos trabajos para estimar el riesgo de incendio (Maselli et al., 2003; Maki et al., 2004; Verbesselt et al., 2006). Sin embargo, se han utilizado distintos índices, según la zona de estudio, sin llegar a conclusiones claras sobre cuál es el más adecuado para estimar el riesgo de incendio o el FMC. A continuación se describen los estudios recientes más destacables.

Maselli et al. (2003) relacionan el riesgo de incendio en una región mediterránea con el NDVI obtenido a partir de imágenes del sensor AVHRR (Advanced Very High Resolution Radiometer). Estos autores se basan en el trabajo de Burgan et al. (1998) en el que se demuestra que valores de NDVI anormalmente bajos en el periodo árido pueden ser debidos mayoritariamente a un estrés hídrico que implica una vegetación más vulnerable a los incendios forestales. Maselli et al. (2003) analizan la relación entre la frecuencia de incendios de un periodo de 10 días y el NDVI de ese periodo y de los dos periodos anteriores. Las correlaciones que obtienen muestran que se puede establecer una relación entre estos parámetros, sin embargo, los resultados no son suficientemente buenos como para establecer un modelo de predicción. Para mejorarlo repiten las regresiones teniendo en cuenta los distintos usos de suelo presentes en la región de estudio, basándose en la clasificación de usos del suelo del CORINE (Coordination of Information on the Environment) Land Cover (Annoni & Perdigao, 1997). Tampoco así consiguen un buen modelo, posiblemente debido a que el CORINE distingue bien entre usos de suelo pero no entre tipos de vegetación. Finalmente, analizan las correlaciones per-pixel entre las variaciones inter-anales de NDVI y frecuencia de incendios, basándose en la hipótesis que existen píxeles más sensibles a los incendios, y de esta forma sí se obtienen mejores resultados.

En Maki et al. (2004) se utiliza el NDWI y se relaciona con el FMC y el EWT. El FMC y el EWT se miden en el laboratorio utilizando muestras de baladre, árbol de las tulipas y abedul. Las imágenes de satélite que utilizan corresponden a

incendios forestales en el este de Rusia. Encuentran que el NDWI no se puede relacionar con el FMC pero sí con el EWT (relación lineal con R^2 entre 0,78 y 0,88), lo que significa que el NDWI está fuertemente relacionado con la cantidad de agua por unidad de área pero no con la cantidad de agua por unidad de peso de vegetación seca. Por tanto, el NDWI no es un buen índice por sí solo para estimar el estrés hídrico de la vegetación, para ello se necesita conocer el área foliar que puede estimarse mediante el NDVI. A partir de estos dos índices Maki et al. (2004) definen un nuevo índice, el VDI (Vegetation Dryness Index) para estimar el déficit de agua de la vegetación, y comprueban que los píxeles quemados tenían el VDI más alto antes del incendio, además comprueban que la rapidez de propagación del fuego aumenta de forma lineal con el VDI.

Chuvienco et al. (2004a) buscaron la mejor forma de relacionar el FMC con los datos de satélite. Para ello utilizaron tres sensores distintos: AVHRR, Vegetation y TM (Thematic Mapper). A partir de datos de estos sensores se obtienen los índices de vegetación NDVI y NDII, la temperatura de la superficie (LST) y el cociente NDVI/LST, y se analiza la relación de cada uno de estos parámetros con el FMC, distinguiendo entre pastizales y zonas con arbustos. Chuvienco et al. (2004a) observan que el NDVI presenta mayor correlación con el FMC en la zona de pastizales que en la zona de arbustos para todos los sensores, de hecho observan una correlación significativa entre el NDVI y el FMC para los pastizales pero no es así en las zonas de arbustos. En cambio el NDII sí que presenta una correlación significativa tanto en los pastizales como en la zona de arbustos. Finalmente, se obtienen también buenos resultados al relacionar el cociente NDVI/LST con el FMC. En base a las buenas correlaciones obtenidas, se definen unas ecuaciones para estimar el FMC de pastizales y arbustos por separado a partir del NDVI, la LST y el día juliano para tener en cuenta las variaciones estacionales. El método desarrollado se aplica a nuevos datos de FMC obtenidos en una campaña de campo y se obtienen coeficientes de correlación entre los valores observados y predichos de 0,85 en los pastizales y de 0,69 en arbustos.

En otro trabajo, Chuvienco et al. (2004b), definen un índice (ignition potential: IP) a partir del FMC. Para ello se basan en el concepto de humedad de extinción (moisture extinction: ME), que se define como el valor del contenido en humedad por encima del cual un incendio no se puede mantener (Rothermel, 1972). La humedad de extinción varía dependiendo de la especie vegetal. Se asigna al IP el valor de 0,2 cuando el FMC es igual al ME, para valores menores del

FMC, el IP tomará valores en el rango 0,2-1, siguiendo el IP una relación lineal inversamente proporcional al FMC. Los valores de ME para las distintas especies se toman de la bibliografía. El FMC de los combustibles muertos se obtiene a partir de información meteorológica mientras que para los combustibles vivos utilizan imágenes NOAA-AVHRR aplicando la metodología descrita en Chuvieco et al. (2004a), sin embargo, esta metodología únicamente es aplicable a zonas de pastizales y arbustos pero no a zonas boscosas. El método presentado en este trabajo es muy interesante, sin embargo se aprecian importantes dificultades como son el no poder aplicarse a zonas boscosas y la necesidad de conocer las especies vegetales presentes en la región así como el correspondiente valor de ME para cada una de ellas.

Stow et al. (2005) comparan las relaciones FMC-NDWI y FMC-VARI en una región de chaparral. Encuentran que el VARI presenta una mayor correlación con el FMC que el NDWI, lo cual sorprende porque el VARI se basa únicamente en bandas del visible, mientras que el NDWI se basa en una banda de absorción de agua. Estos autores suponen que la variabilidad temporal del verdor de la cubierta vegetal y de la humedad de las hojas está relacionada con la respuesta a la precipitación, de forma que el VARI se puede usar para predecir el FMC.

Verbesselt et al. (2006) comparan dos índices espectrales (NDVI y NDWI) obtenidos a partir de datos de satélite y un índice relacionado con la meteorología (KBDI, Keetch-Byram Drought Index) como indicadores del riesgo de incendio en una región de sabana en el noreste de Sudáfrica. Se observa que los índices espectrales, en especial el NDWI, funcionan mejor que el KBDI. Además, los resultados muestran que estos índices de riesgo de incendio relacionados con el estado hídrico de la vegetación empiezan a disminuir antes de que llegue la época de incendios, con lo cual se pueden utilizar para predecir el comienzo de la época de incendios.

Cheng et al. (2006) estudian tres zonas diferentes: una zona de cultivo, una zona semiárida con arbustos y un bosque boreal. Estos autores comparan el EWT obtenido a partir de datos del sensor AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) con cuatro índices obtenidos a partir del sensor MODIS (NDVI, EVI, NDWI y SWISI). Los cuatro índices presentan una relación lineal con el EWT en las tres zonas. En la zona de cultivo, el EVI presenta el mejor coeficiente de correlación en la época en que el cultivo está completamente verde y creciendo exponencialmente. En la zona semiárida, el mejor coeficiente de correlación se

obtiene con el NDVI, y en el bosque boreal, funcionan mejor los índices SWISI y NDWI.

Yebra et al. (2008) comparan dos métodos distintos, uno empírico, basado en regresión lineal multivariante entre el FMC y reflectividades del sensor MODIS, y otro simulado, derivado de modelos de transferencia radiativa. Distintos índices de vegetación se incluyeron como variables independientes en el modelo empírico. En el modelo teórico, se simularon las reflectividades entre los 400 y 2500 nm para distintos valores de FMC, utilizando los modelos PROSPECT (Jacquemoud and Baret, 1990) y SAILH (Verhoef W, 1984). Al igual que en Chuvieco et al. (2004a) y Chuvieco et al. (2004b), se distingue entre pastizales y arbustos, y no se analiza el caso de bosques densos. Empleando el modelo empírico se obtienen mejores correlaciones entre el FMC real y estimado en las zonas de pastizales, especialmente cuando utilizan los índices EVI, NDVI y SAVI, mientras que en los arbustos las mejores correlaciones se obtienen con los índices NDII, GVMÍ y NDWI. Al desarrollar modelos de regresión lineal múltiple a partir del modelo empírico, los mejores resultados para todas las muestras de pastizales se obtienen cuando se utiliza el NDVI.

1.6. Objetivos de la Tesis

Como ya se ha mencionado anteriormente, la lucha contra los incendios forestales es muy importante para nuestra sociedad, y en este sentido la prevención juega un papel clave. El objetivo de esta Tesis Doctoral es determinar un buen parámetro relacionado con el estrés hídrico de la vegetación, a partir de datos de satélite, para introducirlo en un sistema de predicción de riesgo de incendio junto a otros parámetros adicionales. En concreto en esta Tesis se obtendrá un índice de riesgo de incendio basado en los índices de vegetación. Por motivos de cobertura espacial y temporal de los datos de satélite hacemos uso del sensor MODIS a bordo de la plataforma Terra. Ese parámetro, obtenido a partir de información de los índices de vegetación, integrado con el periodo del año y con el historial de incendios de la zona de estudios, mediante la regresión logística compondrá un modelo sencillo de predicción de riesgo de incendio.

Los pasos a seguir para conseguir los objetivos son, a grandes rasgos:

- Descarga y almacenaje de las imágenes de satélite: las imágenes MODIS están disponibles en la página web de la NASA y se pueden descargar gratuitamente.
- Procesado de las imágenes: las imágenes de satélite necesitan de un proceso de filtrado para eliminar los píxeles con nubes o errores del sensor, además llevaremos a cabo un proceso de rellenado para ganar información y finalmente tendremos que adecuar la escala espacial de las imágenes a la resolución de los datos de incendios.
- Obtención de las relaciones entre los distintos índices de vegetación analizados y la frecuencia de incendios: utilizando el 50% de los datos buscaremos la mejor relación entre los índices de vegetación y la frecuencia de incendios.
- Validación de las relaciones obtenidas: aplicar las relaciones obtenidas anteriormente a los datos reservados para validar (el otro 50%) y comparar los datos de incendios reales con los predichos por el modelo.
- Selección del mejor índice, de entre los analizados, para caracterizar el riesgo de incendio en las regiones de estudio.
- Combinación del índice de vegetación, el periodo del año y el historial de incendios de la zona mediante regresión logística para la obtención de un modelo de riesgo de incendio.
- Clasificación en niveles de riesgo; los sistemas de lucha contra los incendios forestales trabajan con escalas graduadas de riesgo por lo que buscaremos la mejor clasificación basándonos en los resultados del modelo.

1.7. Estructura de la Memoria

Esta Memoria se ha estructurado en cuatro capítulos. En el Capítulo 1 hemos analizado la base del estudio, los antecedentes sobre el tema y los objetivos perseguidos. A continuación, en el Capítulo 2 se presenta el procesado de las imágenes de satélite y el método para la búsqueda de una relación entre los incendios forestales y la frecuencia de incendios. En el Capítulo 3 se aplican los procedimientos descritos en el Capítulo 2 a dos zonas de estudio distintas, utilizando distintos índices de vegetación, y se selecciona el índice que mejores resultados ofrece. En el Capítulo 4 se utiliza la regresión logística para combinar el índice de vegetación seleccionado en el Capítulo 3 con el periodo del año y el

historial de incendios de la zona, y de este modo obtener un modelo de riesgo de incendio. Y para finalizar, el Capítulo 5 resume, en forma de conclusiones, los resultados más importantes del trabajo.

Adicionalmente, se incluye en los anexos una copia de los artículos publicados en revistas internacionales fruto de esta Tesis Doctoral, así como otra información relativa a las imágenes de satélite utilizadas.

Capítulo 2

Variaciones de los índices de vegetación como indicadores del riesgo de incendio

2.1. Datos de incendios

Los datos de incendios empleados en esta Tesis fueron facilitados por la Universidad de Santiago de Compostela que los recibió del Ministerio de Medio Ambiente y Medio Rural y Marino del gobierno español. Las comunidades autónomas son las encargadas de rellenar los partes de incendios siguiendo las instrucciones del Comité de Lucha contra Incendios Forestales (CLIF, 2006), atendiendo a los siguientes campos:

- **Número de parte:** 4 dígitos correspondientes al año + 2 dígitos correspondientes a la provincia + 4 dígitos del número identificativo.
- **Localización:** comunidad, provincia, comarca o isla, término municipal, hoja del Mapa Militar 1:250.000 y codificación alfanumérica de la malla UTM de 10x10 km²; opcionalmente se pueden incluir las coordenadas UTM, la entidad menor y el paraje.
- **Tiempos** de detección, de llegada de las brigadas, de control y de extinción.
- **Detección:** ha de marcarse por quién ha sido detectado (vigilante, agente forestal, llamada particular, etc.) y junto a qué zona se ha iniciado (carreteras, casas, ferrocarril, etc.).
- **Causas:** ha de marcarse si la causa señalada es cierta o supuesta. Las posibles causas son: rayo, negligencias y causas accidentales, intencionado, causa desconocida o incendio reproducido. Señalar si el causante es conocido o no y su motivación. Marcar si el día de inicio del incendio era festivo, laborable, laborable víspera de festivo o sábado.
- **Condiciones de peligro del incendio:** datos meteorológicos, modelos de combustible en la zona del incendio y peligro meteorológico.
- **Tipo de fuego:** de superficie, de copa o de subsuelo.
- **Medios utilizados en la extinción:** transporte de personal terrestre, personal, medios pesados y medios aéreos.
- **Técnicas de extinción:** ataque directo o indirecto.
- **Pérdidas:** víctimas, superficies afectadas por el fuego, efectos ambientales, incidencias de Protección Civil, si afectó a Espacios Naturales Protegidos o a Reforestación de Zonas Agrarias.
- **Datos particulares del monte:** comarca, término municipal, situación legal del monte y número de identificación del monte.
- **Superficies afectadas por el fuego.**

- **Valoración de pérdidas.**
- **Datos de espacios naturales protegidos.**

La información de los incendios que se utiliza en esta Tesis está basada en la cuadrícula UTM de 10x10 km². El motivo es que la información disponible consta del número de incendios por día y por cuadrícula además de las coordenadas de la cuadrícula. Los sistemas de lucha contra los incendios forestales trabajan en base a esta misma cuadrícula.

El periodo de estudio corresponde a los años 2001-2006. Se eligió este periodo porque el satélite que utilizamos para monitorizar la vegetación empezó a funcionar en febrero del 2000, por lo que el primer año completo de imágenes fue el 2001. Los datos de incendios de años más recientes no estaban disponibles al inicio de la investigación.

Se decidió trabajar con periodos de aproximadamente dos semanas (sumando para cada casilla el número de incendios en ese periodo) porque no se esperan cambios significativos en la vegetación en un periodo inferior, de hecho la reacción de la vegetación ante los cambios en la disponibilidad de agua no es instantánea. Además, en algunas regiones españolas la cobertura nubosa es tradicionalmente muy alta, lo que supone un problema a la hora de adquirir información de la superficie desde satélite. Si utilizamos composiciones temporales de imágenes, este problema se verá disminuido.

2.2. Imágenes de satélite

El sensor MODIS es un instrumento a bordo de la plataforma TERRA (figura 2.1). Este satélite tiene una órbita polar, con un periodo de revisita de 1 día en España, de forma que pasa todos los días por la mañana de norte a sur y por la noche de sur a norte en el ecuador. Se lanzó en diciembre de 1999 y comenzó a tomar imágenes en febrero del 2000. El sensor MODIS adquiere información en 36 bandas espectrales, desde los 0,4 μm hasta los 14,4 μm (ver anexo A), con diferente resolución espacial dependiendo de la banda (250 m, 500 m, 1000 m), y la distribuye mediante distintos productos operativos. La elección de este sensor para esta Tesis ha sido motivada por su resolución temporal y espacial. Por un

lado, dado que trabajamos con cuadrículas de $10 \times 10 \text{ km}^2$ no necesitamos gran resolución espacial. Por otro, el hecho de disponer de imágenes diarias permite realizar una composición de distintas fechas, de forma que se puede obtener una imagen de cada dos semanas aunque no estén todas las imágenes diarias disponibles. Otros satélites con mayor resolución espacial, como por ejemplo el Landsat 7, tienen un periodo de revisita de 16 días, de forma que si el día de captura de la imagen hay nubes no se obtiene información de la superficie en todo ese periodo de 16 días. Otra ventaja de las imágenes MODIS es que algunos productos se proporcionan ya corregidos tanto geoméricamente como del efecto de la atmósfera, lo cual simplifica el uso de estas imágenes.




Figura 2.1. Imagen del sensor MODIS en la plataforma Terra.

En esta Tesis se han utilizado imágenes de los productos MOD13Q1 (Huete et al., 1999) y MOD09A1 (Vermote & Vermeulen, 1999) descargadas de la página web del LP DAAC (Land Processes Distributed Active Archive Center) https://lpdaac.usgs.gov/lpdaac/get_data.

2.2.1. Producto MOD13Q1

El producto MOD13Q1 utiliza las reflectividades de los canales centrados en el azul (469 nm), el rojo (645 nm) y el infrarrojo cercano (858 nm) para calcular dos índices de vegetación: el NDVI y el EVI. Estos índices se obtienen a partir de

las reflectividades del suelo corregidas atmosféricamente. El producto MOD13Q1 proporciona una imagen cada 16 días con una resolución espacial de 250 m. La versión 5 del producto de índices de vegetación de MODIS está validada al nivel 2, lo cual quiere decir que la precisión ha sido comprobada en un amplio conjunto de sitios y en distintas ocasiones a partir de medidas in situ (Gao et al., 2003, Huete et al., 2002).

Las imágenes del producto MOD13Q1 contienen 12 bandas con la siguiente información:

1. NDVI
2. EVI
3. Banda de calidad de los índices de vegetación
4. Reflectividad en el rojo (620-670 nm)
5. Reflectividad en el infrarrojo cercano (841-876 nm)
6. Reflectividad en el azul (459-479 nm)
7. Reflectividad en el infrarrojo medio (2105-2155 nm)
8. Ángulo cenital de observación
9. Ángulo solar cenital
10. Ángulo acimutal relativo
11. Composición del día del año
12. Fiabilidad del píxel

La banda 3 proporciona información de la calidad del píxel, en concreto de las condiciones en que se ha tomado la medida (si había nubes, sombras, hielo, si la medida es muy fiable o no, etc.). Dicha información está codificada en un número binario de 16 bits, donde cada conjunto de bits aporta una información diferente. En el anexo B se incluye la tabla en la que se explica la información que proporciona cada conjunto de bits.

Para esta Tesis se han empleado las bandas 1 y 2 que proporcionan los índices de vegetación NDVI y EVI (Figura 2.2), y la banda 3 para conocer las condiciones en las que se ha medido cada píxel y eliminar aquellos que presenten información contaminada o poco fiable.

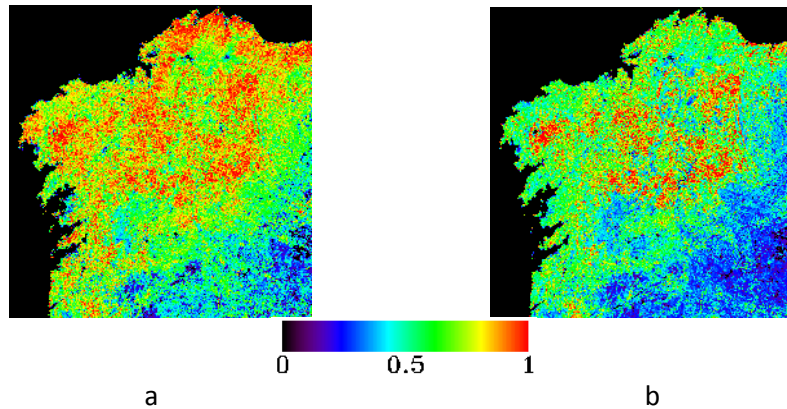


Figura 2.2. Ejemplo de imágenes del producto MOD13Q1 correspondientes al período 10-25 Junio de 2003 y a la región de Galicia: a) EVI, b)NDVI

2.2.2. Producto MOD09A1

El producto MOD09A1 proporciona las reflectividades corregidas atmosféricamente en las 7 primeras bandas del sensor MODIS, las cuales están centradas en las siguientes longitudes de onda: 0,648 μm , 0,858 μm , 0,470 μm , 0,555 μm , 1,240 μm , 1,640 μm , y 2,13 μm . Este producto proporciona una imagen cada 8 días con una resolución espacial de 500 m. Cada píxel contiene el valor correspondiente a la mejor observación del periodo, es decir, la observación con mayor cobertura, menor ángulo y sin nubes o sombras.

Las imágenes de este producto contienen las siguientes capas:

1. Reflectividad en el rojo (620-670 nm)
2. Reflectividad en el infrarrojo cercano (841-876 nm)
3. Reflectividad en el azul (459-479 nm)
4. Reflectividad en el verde (545-565 nm)
5. Reflectividad en el infrarrojo medio (1230-1250 nm)
6. Reflectividad en el infrarrojo medio (1628-1652 nm)
7. Reflectividad en el infrarrojo medio (2105-2155 nm)
8. Banda de calidad de las reflectividades (da información de la calidad de la medida en cada banda)
9. Ángulo solar cenital
10. Ángulo de visión cenital
11. Ángulo acimutal relativo

- 12. State flags (da información de las condiciones de medida de cada píxel, es equivalente a la capa 3 del producto MOD13Q1)
- 13. Día del año

La banda 8 proporciona información de la calidad y correcciones realizadas en cada banda, en cambio la banda 12 proporciona información, en código binario, de las condiciones en que se ha tomado la medida de cada píxel (si había nubes, sombras, hielo, si la medida es muy fiable o no, etc.), información que es la misma para las 7 bandas. En el anexo C se incluye una tabla en la que se explica la información que proporciona cada conjunto de bits en los que viene codificada. En concreto en esta Tesis utilizamos las bandas 1 a 6 para calcular distintos índices de vegetación (Tabla 2.1), y la banda 12 para conocer las condiciones en las que se ha medido cada píxel y eliminar aquellos que presenten información contaminada o poco fiable.

Tabla 2.1. Índices de vegetación definidos a partir de las bandas del sensor MODIS.

Normalized Difference Vegetation Index	$NDVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1}$	Rouse et al., 1974
Soil Adjusted Vegetation Index	$SAVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1 + L} \left(\frac{1}{1 + L} \right), \quad L=0,25$	Huete, 1988
Normalized Difference Infrared Index	$NDII = \frac{\rho_2 - \rho_6}{\rho_2 + \rho_6}$	Hardisky, 1983
Global Environmental Monitoring Index	$GEMI = \frac{\rho_2 - 0,125}{1 - \rho_1} \left(\frac{\rho_2 - \rho_1}{\rho_2 + \rho_1 + 0,5} + 1,5 \right)$	Pinty and Verstraete, 1992
Normalized Difference Water Index	$NDWI = \frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$	Gao, 1996
Visible Atmospheric Resistant Index	$VARI = \frac{\rho_4 - \rho_1}{\rho_4 + \rho_1 - \rho_3}$	Gitelson et al., 2002
Enhanced Vegetation Index	$EVI = 2,5 \frac{\rho_2 - \rho_1}{\rho_2 + 6\rho_1 - 7,5\rho_3 + 1}$	Huete et al., 2002
Global Vegetation Moisture Index	$GVMI = \frac{(\rho_2 + 0,1) - (\rho_6 + 0,02)}{(\rho_2 + 0,1) + (\rho_6 + 0,02)}$	Ceccato et al., 2002

ρ_i : reflectividad en el canal i del sensor MODIS

2.3. Procesado de las imágenes

Para el procesado de las imágenes MODIS utilizamos un software comercial de tratamiento digital (ENVI). El primer paso fue recortar las imágenes para centrarnos en la zona de estudio, ya que las imágenes MODIS originales descargadas abarcan una superficie de unos 1200x1200 km (4800 filas, 4800 columnas en el caso de las MOD13Q1 y 2400 filas, 2400 columnas en el caso de las MOD09A1). Como ejemplo se muestra a continuación el procesado de las imágenes para la región de Galicia. El recorte de las imágenes se hizo basándose en la cuadrícula de 10x10 km² (Fig. 2.3). De esta forma se obtenían imágenes de ambos productos de la región de Galicia con 928 columnas y 995 filas en el caso del producto MOD13Q1 (Fig. 2.4) y con 464 columnas y 497 filas en el caso del producto MOD09A1.




Figura 2.3. Mapa de Galicia dividido en 360 cuadrículas de 10x10 km².

A continuación se llevó a cabo un proceso de filtrado de las imágenes para eliminar del estudio los píxeles correspondientes a cuerpos de agua (ríos, lagos, océano) y zonas urbanas (Figura 2.5), ya que estos píxeles que no son de vegetación contaminarían el estudio si no se eliminasen. Este proceso se basó en la información del Corine Land Cover 2000 (Bossard et al., 2000).

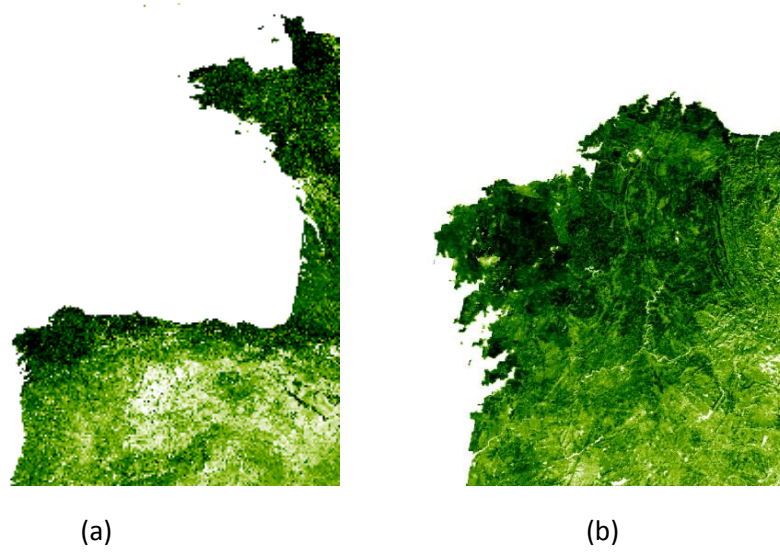


Fig. 2.4. a) Imagen original del producto MOD13Q1, b) imagen recortada.




Figura 2.5. Máscara de cuerpos de agua y grandes ciudades.

Seguidamente se utilizó la banda de calidad de cada producto para eliminar del estudio todos los píxeles con valores erróneos o con nubes, quedándonos únicamente con los píxeles que cumplían las siguientes condiciones (Bisquert et al. 2009): píxeles de tierra sin nubes, sombras o nieve y además cuya información

había sido producida con una calidad entre alta y decreciente (anexos B y C). Un ejemplo de imagen filtrada del producto MOD13Q1 se muestra en la figura 2.6.

En algunas imágenes del producto MOD09A1 se observó un ruido presente únicamente en la banda 5 en forma de líneas diagonales, generalmente de un píxel de grosor, con valores anormalmente altos. Para eliminar este ruido se aplicó una matriz de 3x3 píxeles que calcula la diferencia entre el valor del píxel central y la media de los 8 píxeles que le rodean. Cuando el valor de la resta es superior a un umbral pre-establecido se considera que el píxel central presenta ruido y queda automáticamente filtrado (Bisquert et al., 2010a).

A pesar de trabajar con una imagen, resultado de la composición de 16 imágenes diarias (producto MOD13Q1) o de 8 imágenes diarias (producto MOD09A1), en algunas zonas las nubes son muy frecuentes y pueden quedar muchos huecos sin información en las imágenes. Con el fin de minimizar estos huecos y de rellenar los píxeles filtrados, ganando así algo de información, se llevó a cabo un proceso de rellenado a partir de la información de los píxeles vecinos. Creamos una matriz de 5x5 píxeles que se aplicaba a todos aquellos píxeles catalogados como erróneos y les asignaba el valor medio de los píxeles de alrededor de los que se disponía de información. Un ejemplo de imagen rellenada se presenta en la figura 2.7. Para comprobar que este proceso de rellenado era correcto se aplicó a píxeles del producto MOD13Q1 de los que sí se tenía información y se observó que en el 90% de los casos la diferencia del EVI entre aplicar el proceso de rellenado y no aplicarlo era inferior a 0,1. Teniendo en cuenta que finalmente íbamos a trabajar con valores promedio dentro de cada cuadrícula de 10x10 km², estas diferencias no se consideraron importantes.

En el caso de las imágenes del producto MOD09A1 se llevan a cabo dos procesos extra, el primero es el cálculo de los índices de vegetación presentados en la tabla 2.1, y el segundo es un proceso de composición de dos imágenes consecutivas con el fin de obtener una imagen de cada 16 días que guarde homogeneidad temporal con las imágenes del producto MOD13Q1. El proceso de composición consiste en tomar la media del índice de vegetación de las dos imágenes consecutivas si se tiene valor de ambas imágenes, o bien asignar el valor disponible en caso de que solo se conozca éste en una de las imágenes.




Figura 2.6. Imagen recortada e imagen filtrada (MOD13Q1).




Figura 2.7. Imagen filtrada e imagen rellenada (MOD13Q1).

El último paso para ambos productos consistió en asignar un valor a cada cuadrícula de $10 \times 10 \text{ km}^2$. Para ello, se calculó el valor medio de todos los píxeles de cada casilla, siempre y cuando hubiera al menos un 10% de tierra y estuvieran enmascarados como máximo el 20% de estos píxeles (Fig. 2.8). De esta forma se pretende que al hacer la diferencia de una cuadrícula entre dos imágenes consecutivas, la información contenida en ambos casos sea similar, esto es importante porque en una cuadrícula de $10 \times 10 \text{ km}$ pueden aparecer distintos tipos de usos de suelo.




Figura 2.8. Imagen rellena e imagen con el valor medio del EVI por cuadrícula (MOD13Q1).

2.4. Relación entre la frecuencia de los incendios y la variación de los índices espectrales

La variación de los índices entre dos fechas indica el aumento o disminución del verdor de la vegetación, lo cual está relacionado con el estado hídrico de las plantas, como se explicó en el capítulo 1. Por esta razón se decidió enfrentar las variaciones de los índices entre dos periodos consecutivos de 16 días y la frecuencia de incendios registrados en el periodo posterior.

En primer lugar, restamos los valores del índice de vegetación para dos imágenes consecutivas. A continuación, agrupamos las casillas en intervalos de 0,01 en términos de variación del índice y contabilizamos todas las casillas en las que se había registrado algún incendio en cada intervalo. Para que las variaciones sufridas por el índice fueran consecuencia de factores naturales y no consecuencia de algún incendio, filtramos la base de datos eliminando del estudio las casillas en las que se había registrado algún incendio durante las dos semanas anteriores al periodo de estudio, ya que al haber un incendio se produciría una disminución importante del índice de vegetación. Dividiendo el número de casillas con incendio dentro de cada intervalo de variación del índice entre el número de casillas total del mismo intervalo obtenemos el porcentaje o la frecuencia de casillas con incendio para cada caso.

Al representar gráficamente la también llamada probabilidad de incendio (frecuencia de celdas con incendio) frente a la variación sufrida por el índice, se puede determinar si existe alguna relación entre ellos que nos permita parametrizar la probabilidad de que se produzca incendio, conocida la variación que experimenta el índice de vegetación en una determinada celda.

En la revisión bibliográfica que se muestra en el capítulo 1 se puede ver cómo las relaciones empíricas entre los índices de vegetación y el contenido en agua de las plantas pueden depender del tipo de vegetación considerado. La eficacia de un índice para predecir incendios forestales también puede depender de la zona. Por estos motivos el proceso se aplica con todos los índices de vegetación calculados, con el fin de llevar a cabo una comparación y seleccionar aquel que presente una relación más fuerte en la zona de estudio concreta, para posteriormente desarrollar un modelo de riesgo de incendio incluyendo otros parámetros.

Se utiliza el 50% de la serie temporal para obtener la relación y el otro 50% para la validación. La selección de los dos grupos de datos se hace mediante una función aleatoria.

2.5. Resumen

En este capítulo se ha descrito el procesado de las imágenes MODIS y el procedimiento para buscar una relación entre la frecuencia de incendios de un periodo y los índices de vegetación de los periodos anteriores, en concreto se utiliza la variación experimentada por dichos índices en dos periodos consecutivos.

El procesado de las imágenes consta de los siguientes procedimientos: en primer lugar, se recortan las imágenes para centrarse en la zona de estudio, a continuación, se lleva a cabo un proceso de filtrado, basándose en la información contenida en la banda de calidad, para eliminar píxeles erróneos. En el caso de las imágenes del producto MOD09A1 se lleva a cabo un filtrado extra debido a la presencia de ruido (píxeles con valores anómalos no detectados por la banda de calidad como píxeles erróneos). Seguidamente, para ambos productos, se lleva a cabo un proceso de rellenado para ganar algo de información de los píxeles filtrados previamente. Finalmente, se reescalán los datos para tener la

Variaciones de los índices de vegetación como indicadores del riesgo de incendio

información de los índices de vegetación con la misma resolución espacial que los datos de los incendios forestales (10x10 km).

La búsqueda de una relación entre las variaciones de los índices espectrales previas al periodo de estudio y la frecuencia de incendios de dicho periodo se hace utilizando la mitad de los datos disponibles, reservando la otra mitad para validar las relaciones obtenidas. Consiste en agrupar todos los casos en términos de variación de los índices, de forma que se pueda obtener la frecuencia de incendios para un intervalo de variación de los índices. Seguidamente se representa la frecuencia de incendios frente a las variaciones de los índices, de forma que se puede comprobar si existe algún tipo de relación o no.

Capítulo 3

Aplicación a las zonas de estudio

3.1. Zonas de estudio

La técnica descrita en el capítulo 2 se aplicó a dos comunidades españolas por separado, Galicia y Asturias (ver apéndice D). Galicia es la región española más afectada por los incendios forestales, a pesar de tener un clima húmedo y una alta densidad de vegetación lo que hace que muchos modelos globales de riesgo de incendio fallen en dicha región. Por esta razón en esta Tesis nos hemos centrado en la región de Galicia aunque también aplicamos el modelo a la región vecina de Asturias, con un número de incendios muy inferior, y con un comportamiento del régimen de incendios anual muy distinto al de Galicia (Fig.3.1), con el fin de comprobar la aplicabilidad del modelo a zonas con menos incendios. En la figura 3.1 se comprueba que en ambas comunidades se presentan dos picos de incendios, el primero centrado en el mes de marzo y el segundo en los meses de verano (agosto), sin embargo se observa que en Galicia el pico del verano es más importante que el de marzo, mientras que en Asturias ocurre lo contrario.




Figura 3.1. Número de incendios medio en periodos de 16 días para Galicia y Asturias.

Galicia, situada al noroeste de la Península Ibérica, ocupa una superficie de 29.575 km², mientras que Asturias, región vecina, ocupa 10.604 km². En torno al 70% de la superficie de ambas regiones es forestal (Ministerio de Medio Ambiente y Medio Rural y Marino, 1997). Históricamente, el bosque gallego era un bosque

de especies caducifolias como el roble y su particular sotobosque, sin embargo en la década de los 50 estos bosques sufrieron varias deforestaciones, consecuencia de la demanda de madera y carbón vegetal, y del aumento de la agricultura extensiva. En la misma década se llevó a cabo una reforestación masiva de especies de crecimiento rápido como el pino y el eucalipto. Actualmente, la vegetación mayoritaria son los bosques de coníferas (especialmente de pino resinero), y las especies frondosas como el roble y el eucalipto (tabla 3.1). En Asturias, en cambio, son más abundantes los bosques de especies frondosas, principalmente formados por castaño común, hayas y robles, aunque se encuentran también poblaciones considerables de coníferas (especialmente de pino resinero). En ambas comunidades existen, además, grandes superficies de pastizales, aunque también éstas se han visto disminuidas considerablemente debido al abandono de las prácticas rurales, la disminución de ganadería extensiva y la proliferación de establos industriales para la cría de ganado.

Las coníferas son plantas leñosas, generalmente son árboles perennes con hojas en forma de aguja. Aparecen principalmente en zonas frías, donde forman grandes bosques. En cuanto a las especies frondosas hay tanto de hoja perenne como caducifolias. El roble es de hoja caduca, mientras que el eucalipto es de hoja perenne.

Ambas regiones poseen un clima templado, de transición entre los climas oceánico y mediterráneo, con inviernos suaves y veranos frescos. Además, son regiones que reciben una considerable cantidad anual de lluvia (en torno a 1300 mm anuales en Galicia y a 900 en Asturias entre los años 1997-2008) debido a los vientos dominantes del oeste que traen masas de aire húmedas. Los meses más lluviosos son octubre, noviembre y diciembre, seguidos de los meses de primavera (fig. 3.2). En verano las precipitaciones medias son inferiores a los 60 mm en ambas regiones (INE, 2010).

En España, entre los años 1996-2005 se produjeron una media anual de 20.887 incendios, de los cuales, aproximadamente el 60% fueron intencionados (Ministerio de Medio Ambiente, 2006). En este período, la superficie forestal media quemada cada año alcanza las 123.459 ha. En concreto la Comunidad de Galicia es una zona especialmente afectada por los incendios forestales, en ella tienen lugar más del 50% de los incendios de España (Figura 3.3), mientras que en Asturias tienen lugar el 8%. En cuanto a la superficie forestal afectada, el 25% del total de España se encuentra en Galicia. Por todo esto es especialmente importante la obtención de modelos de riesgo de incendio en la región gallega.

Tabla 3.1. Especies vegetales dominantes en Galicia y Asturias (Ministerio de Medio Ambiente y Medio Rural y Marino, 1997).

	Especie	Área basimétrica en m ² y %			
		Galicia		Asturias	
Coníferas	Fraxinus Spp.	8461	0.001	12644	0.002
	Pynus Pinaster	7034003	0.467	731436	0.130
	Pynus Sylvestris	410673	0.027	138863	0.025
	Pynus Radiata	785655	0.052	286124	0.051
	Otras coníferas	6561	0.000	19702	0.003
Frondosas	Alnus Glutinosa	133453	0.009	50645	0.009
	Castanea Sativa	1314735	0.087	1800535	0.319
	Eucalyptus Globulus	1832088	0.122	345641	0.061
	Populus Nigra	16124	0.001	2025	0.000
	Quercus Ilex	11181	0.001	13696	0.002
	Quercus Robur/Petraea	2143026	0.142	589135	0.104
	Betula Spp.	487640	0.032	117881	0.021
	Eucalyptus Camaldulensis	63172	0.004	0	0.000
	Fagus Sylvatica	1688	0.000	1266447	0.225
	Quercus Pyrenaica/Pubescons	540009	0.036	115646	0.021
	Quercus Suber	67782	0.005	0	0.000
	Otros árboles ripícolas	76671	0.005	19606	0.003
	Otras frondosas	116066	0.008	129621	0.023




Figura 3.2. Precipitación media anual en Galicia y Asturias en el período 1997 – 2008.

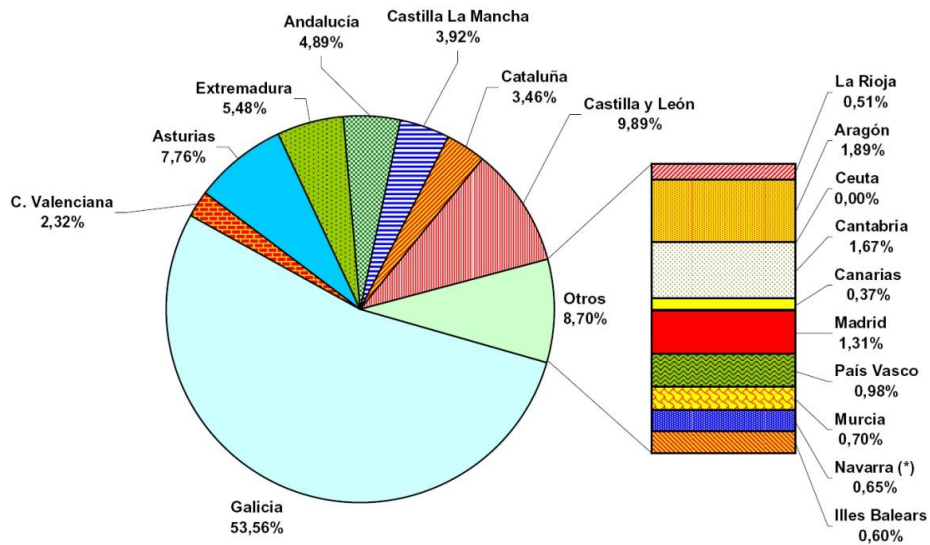


Figura 3.3. Porcentaje de incendios por comunidad autónoma, decenio 1996-2005. (Adaptado de Ministerio de Medio Ambiente, 2006).

3.2. Relaciones entre la frecuencia de incendios y los índices de vegetación

El procesado de las imágenes descrito en la sección 2.3, el cual incluye el recorte de las imágenes, el filtrado, el rellenado, el redimensionado y la composición de dos imágenes consecutivas, se realizó por separado para las regiones de Galicia y Asturias. El recorte de las imágenes de Asturias se hizo en base a la cuadrícula correspondiente a esta región (figura 3.4).

El proceso de búsqueda de una relación entre la variación de los índices y la frecuencia de incendios en cada cuadrícula también se realizó por separado para las dos regiones y para los 8 índices espectrales presentados en la tabla 2.1. De acuerdo con el proceso descrito en la sección 2.4 representamos gráficamente la frecuencia de incendios observada frente a las variaciones de los distintos índices (figuras 3.5 y 3.6).




Figura 3.4. Mapa de Asturias dividido en 146 cuadrículas de 10x10 km².

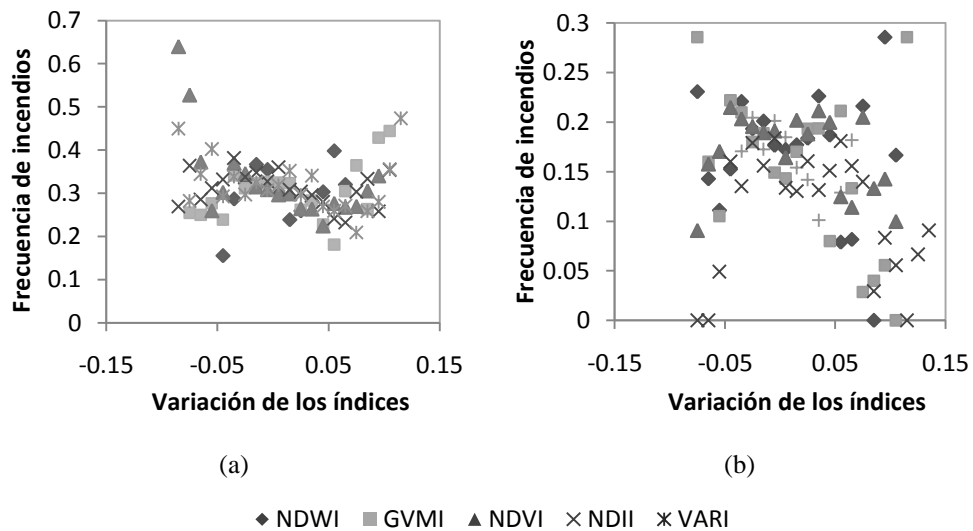


Figura 3.5. Relación entre la frecuencia de incendios y distintos índices espectrales para: a) Galicia, y b) Asturias.

En primera instancia se observa que para cinco de los índices espectrales estudiados, la dispersión de los puntos en la gráfica hacía imposible cualquier tipo de ajuste (figura 3.5), mientras que para los otros tres sí se aprecia una relación clara entre ambos parámetros (figura 3.6). Estos últimos índices cuyas variaciones muestran una relación evidente con la frecuencia de incendios son el EVI (tanto el proporcionado por el producto MOD13Q1 como el calculado a partir del producto MOD09A1), el GEMI y el SAVI. Se probaron distintos tipos de ajustes, pero finalmente se seleccionó el ajuste lineal por ser el que mejor se ajustaba, además de por su simplicidad, obteniéndose coeficientes de regresión (R^2) desde 0,78 con

el SAVI hasta 0,84 con el EVI (MOD13Q1) en Galicia, y desde 0,60 con el SAVI hasta 0,70 con el EVI (MOD09A1) en Asturias. En ambas regiones, las variaciones del índice EVI son las que mejor reproducen la probabilidad de incendio. Se observan comportamientos similares en ambas comunidades, sin embargo, en la región gallega la frecuencia de incendios siempre es mayor que en Asturias para un mismo valor de variación del índice, debido al mayor número de incendios en esta región. En la tabla 3.2 se presentan los resultados estadísticos de los ajustes para los índices EVI, GEMI y SAVI correspondientes a los gráficos de la figura 3.6.

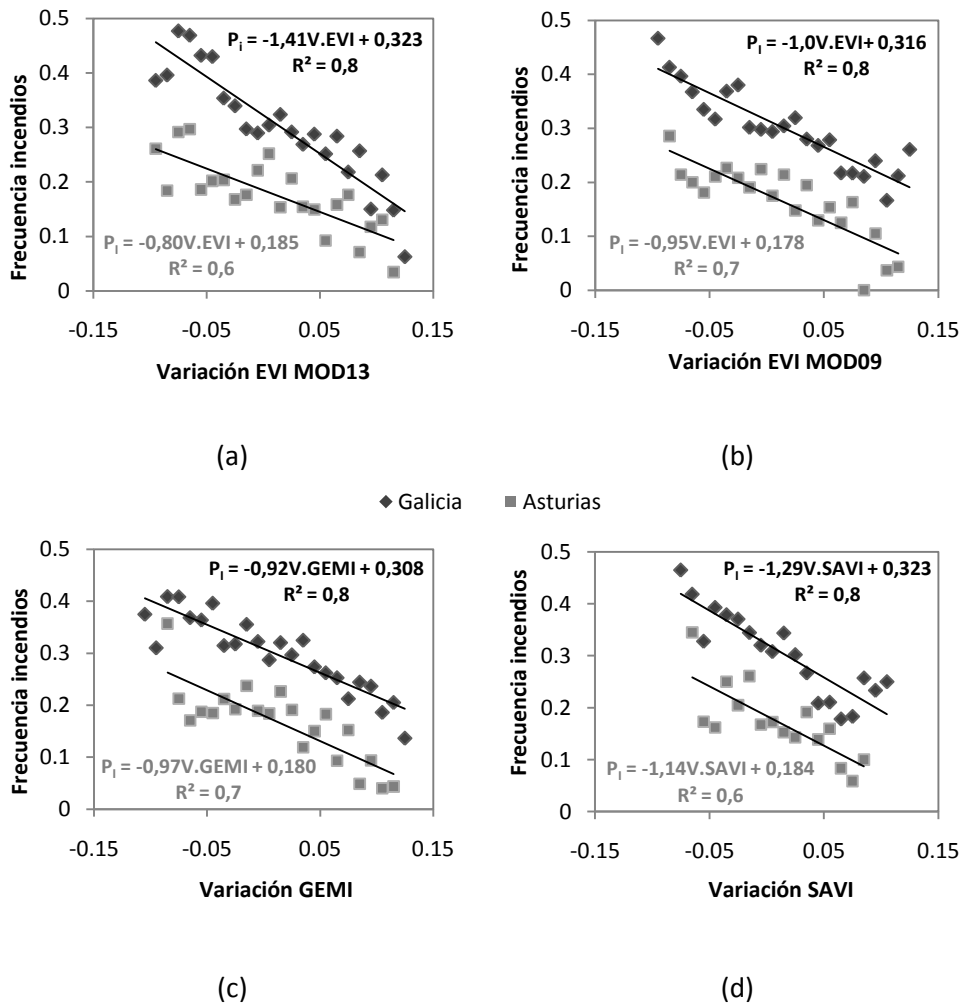


Figura 3.6. Relación entre la frecuencia de incendios y la variación de los índices: a) EVI MOD13Q1, b) EVI MOD09A1, c) GEMI, y d) SAVI.

Tabla 3.2. Resultados de las regresiones lineales entre la frecuencia de incendios y las variaciones de los índices (a: pendiente, b: ordenada en el origen, r^2 : coeficiente de regresión, σ : desviación estándar, N: número de sucesos considerados).

Región	Índice	a	b	r^2	σ	N
Galicia	EVI (MOD13)	-1,41±0,13	0,323±0,009	0,8	0,04	7331
	EVI (MOD09)	-1,00±0,10	0,316±0,007	0,8	0,03	7509
	GEMI	-0,92±0,09	0,308±0,007	0,8	0,03	7509
	SAVI	-1,29±0,17	0,322±0,009	0,8	0,04	7514
Asturias	EVI (MOD13)	-0,80±0,14	0,185±0,009	0,6	0,04	2778
	EVI (MOD09)	-0,95±0,14	0,178±0,009	0,7	0,04	2960
	GEMI	-0,97±0,16	0,180±0,010	0,7	0,04	2930
	SAVI	-1,14±0,25	0,184±0,012	0,6	0,05	2947

3.3. Validación

Una vez establecidas las ecuaciones que relacionan la frecuencia de incendios con las variaciones de los índices, es necesario proceder a su validación. Dicha validación consistió en aplicar las ecuaciones obtenidas a los datos reservados para tal efecto y comparar las frecuencias o probabilidades de incendio predichas por el modelo con los valores de frecuencia real de incendios registrados (Bisquert et al., 2010a).

La figura 3.7 muestra las gráficas de la validación de los distintos índices de vegetación para las dos zonas de estudio. Los mejores resultados, tanto en Galicia como en Asturias, se obtienen empleando el EVI proporcionado por el producto MOD13Q1, con pendientes de 0,97 y 0,71, ordenadas en el origen de 0,01 y 0,06 y coeficientes de regresión de 0,81 y 0,62 para Galicia y Asturias respectivamente. Si comparamos entre regiones, los resultados de la validación son mejores en Galicia que en Asturias, probablemente debido al elevado número de incendios en la región gallega que ayuda a mejorar la estadística.

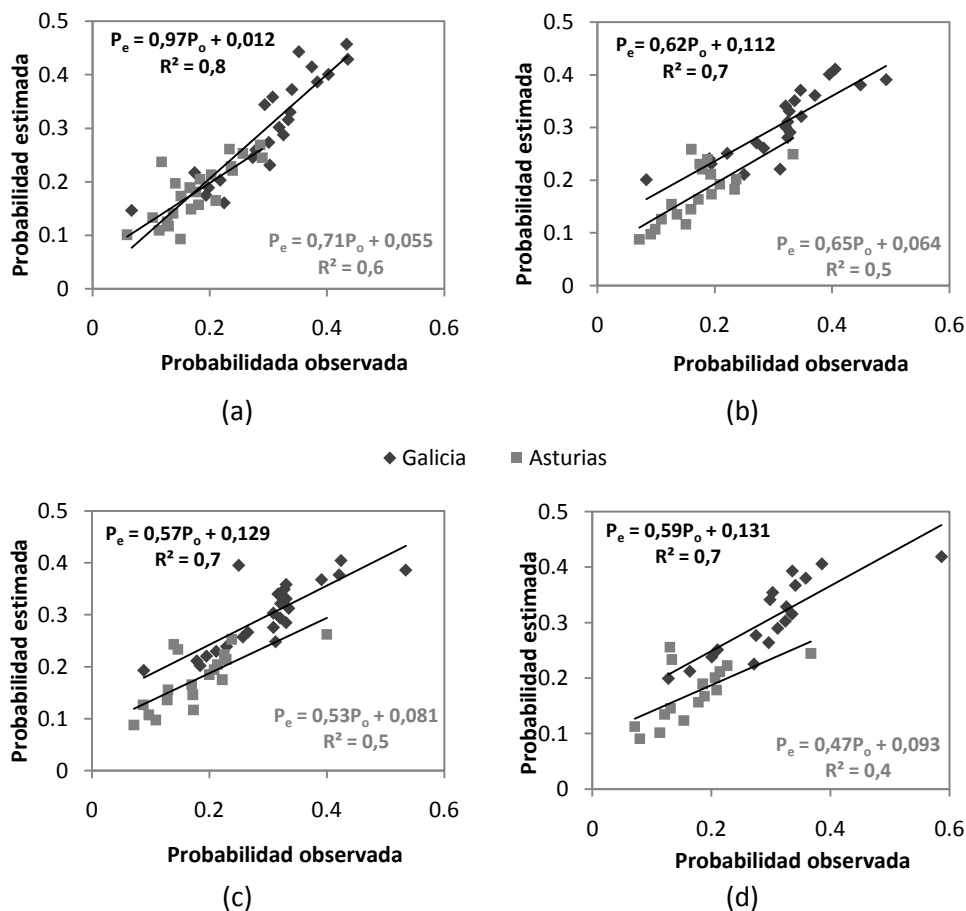


Figura 3.7. Comparación entre la frecuencia de casillas con incendio predicha por el modelo y la frecuencia real de casillas con incendios utilizando los índices: a) EVI MOD13Q1, b) EVI MOD09A1, c) GEMI, y d) SAVI.

La tabla 3.3 se completa con un análisis estadístico, basado en Willmott (1982), de acuerdo con el cual se han calculado el BIAS (diferencia típica entre el valor esperado y el real), el RMSE (error cuadrático medio), el RMSES (error cuadrático medio sistemático), el RMSEU (error cuadrático medio no sistemático), el MAD (diferencia absoluta media) y el MADP (diferencia absoluta media en porcentaje).

Tabla 3.3. Resultados y análisis estadístico de las regresiones entre los valores de frecuencia de incendio predicha por los distintos índices y los observados para las regiones de Galicia (cursiva) y Asturias.

	a	b	R ²	Bias ¹	RMSE ²	RMSES ³	RMSEU ⁴	MAD ⁵	MAPD ⁶
EVI MOD13	0,97 ± 0,10	0,01 ± 0,03	0,8	0,003	0,04	0,003	0,04	0,03	11%
	0,71 ± 0,12	0,06 ± 0,02	0,6	0,005	0,04	0,019	0,03	0,03	15%
EVI MOD09	0,62 ± 0,08	0,11 ± 0,03	0,7	-0,007	0,05	0,03	0,03	0,04	11%
	0,65 ± 0,14	0,06 ± 0,03	0,5	0,004	0,04	0,02	0,04	0,03	19%
GEMI	0,57 ± 0,09	0,13 ± 0,03	0,7	-0,00017	0,05	0,04	0,04	0,04	12%
	0,53 ± 0,12	0,08 ± 0,02	0,5	-0,0016	0,05	0,03	0,04	0,03	19%
SAVI	0,59 ± 0,09	0,13 ± 0,03	0,7	0,006	0,05	0,04	0,04	0,04	13%
	0,47 ± 0,15	0,09 ± 0,03	0,4	0,003	0,05	0,04	0,04	0,03	21%

$$^1 \text{ Sesgo: } Bias = N^{-1} \sum_{i=1}^N \hat{e}_i - O_i$$

$$^2 \text{ Error cuadrático medio: } RMSE = \left[N^{-1} \sum_{i=1}^N \hat{e}_i^2 \right]^{0,5}$$

$$^3 \text{ Error cuadrático medio sistemático: } RMSES = \left[N^{-1} \sum_{i=1}^N \hat{e}_i'^2 \right]^{0,5}$$

$$^4 \text{ Error cuadrático medio no sistemático: } RMSEU = \left[N^{-1} \sum_{i=1}^N \hat{e}_i - P_i'^2 \right]^{0,5}$$

$$^5 \text{ Diferencia absoluta media: } MAD = N^{-1} \sum_{i=1}^N |P_i - O_i|$$

$$^6 \text{ Diferencia absoluta media en porcentaje: } MAD = 100MAD / \langle O_i \rangle$$

donde P_i y O_i son los valores predichos y observados, respectivamente, y $P_i = aO_i + b$.

Estadísticamente el RMSES es el error que se puede controlar y se debe tratar de reducir al mínimo en un modelo empírico, ya que depende de la

configuración del propio modelo. De los índices de vegetación estudiados, tanto en Galicia como en Asturias, el menor RMSES se obtiene cuando se utiliza el EVI (MOD13Q1). El error absoluto (MADP) también es menor cuando se utiliza dicho índice. La diferencia entre los distintos índices es mayor en el caso de Asturias, donde varía desde el 15% en el EVI (MOD13Q1) hasta el 21% en el SAVI. En Galicia estas diferencias no son tan grandes, oscilando entre el 11% del EVI (MOD13Q1) y el 13% del SAVI. En vista de los parámetros de los ajustes y de los distintos errores analizados, se puede concluir finalmente que el EVI proporcionado por el producto MOD13Q1 es el índice de vegetación más conveniente para ser incluido en los modelos de riesgo de incendio, al menos en zonas de vegetación densa como las analizadas en esta Tesis.

Las diferencias observadas en los resultados de aplicar el EVI del producto MOD13 y el EVI calculado a partir del producto MOD09 vienen dadas por la forma de componer las imágenes de 16 días. En el producto MOD09 se componen las reflectividades de 8 imágenes diarias mediante el método MVC (Maxim Value Composite), es decir, toman la reflectividad máxima de los 8 días, ya que la presencia de nubes hace disminuir la reflectividad, y al coger el valor máximo se eliminan píxeles con nubes. En cambio, para el cálculo de los índices de vegetación, el método MVC no es el más adecuado, por lo que en el producto MOD13 de índices de vegetación, la composición de las imágenes es un proceso mucho más complejo en el que se aplican modelos BRDF (Bidirectional Reflectance Distribution Function) y no se utiliza la técnica del MVC, salvo en los casos en que no se puedan utilizar otras técnicas.

3.4. Resumen

Tras estudiar la relación entre la frecuencia de incendios y las variaciones de ocho índices de vegetación distintos en cuadrículas de $10 \times 10 \text{ km}^2$ en dos regiones distintas, Galicia y Asturias, se observa que solamente en tres de los casos la variación temporal presenta una relación lineal con la frecuencia de incendios, estos índices son el EVI, el GEMI y el SAVI. Las ecuaciones correspondientes a estos índices para las dos regiones de estudio se aplicaron posteriormente a unos datos independientes reservados para validar. Tras enfrentar las frecuencias de incendio estimadas y observadas, y analizar los parámetros de los ajustes, así como una serie de errores estadísticos, se concluye que el EVI proporcionado por el producto MOD13Q1 de MODIS es el índice de vegetación que presenta mayor

relación con los incendios forestales en Galicia y Asturias. Por lo tanto, éste es el índice de vegetación con mayores prestaciones para ser utilizado en los modelos de predicción de riesgo de incendio.

Capítulo 4

Estimación del riesgo de incendio a través de regresión logística

4.1. Regresión logística

La regresión logística es una herramienta muy útil en los problemas de clasificación binaria, es decir, para clasificar la presencia o ausencia de un evento, como puede ser un incendio. Esta técnica permite introducir y analizar distintas variables, así como las interacciones entre ellas. Consiste en ajustar la ecuación 4.1 en la que la variable dependiente, P , debe ser una variable binaria (0 ó 1, ausencia o presencia del evento) y las variables independientes (x_i) pueden ser variables continuas o categóricas. α y β_i son los parámetros que deben ajustarse.

(4.1)

La ecuación 4.1 proporciona la probabilidad de ocurrencia de un evento dadas una serie de variables de entrada (Bisquert et al., 2010b). La clasificación en presencia o ausencia del evento se hace escogiendo un punto de corte (entre 0 y 1), el cual quiere decir que se clasificarán como presencia del evento los casos en los que se obtenga una probabilidad superior al valor del punto de corte.

La función logística describe una curva que tiende a cero para valores negativos de z y que tiende a 1 cuando z toma un valor positivo muy grande (figura 4.1).




Figura 4.1. Curva de la regresión logística.

4.1.1. Análisis de errores y bondad del ajuste

En la regresión logística existen distintas pruebas para analizar la bondad del ajuste y la importancia de cada variable introducida en el modelo.

El test de Wald es un estadístico que sirve para analizar la significancia de cada variable. Si el test de Wald es significativo para una variable en concreto, quiere decir que el parámetro correspondiente a esa variable no es cero y por lo tanto esa variable debe mantenerse en el modelo. Se define como el cociente entre el coeficiente y el error estándar del coeficiente. Si por el contrario se obtiene que el test de Wald no es significativo, dicha variable debe ser eliminada del modelo ya que no afectará a los resultados de la ecuación. El test de Wald se analiza como un χ^2 , cuando la significancia es menor de 0,05 quiere decir que la variable correspondiente es significativa.

La prueba de bondad del ajuste más común es el test de Hosmer-Lemeshow, este test se basa en una tabla de contingencia que divide la muestra en 10 grupos iguales en función de la probabilidad predicha por la ecuación 4.1 y compara el número de eventos predichos por el modelo y el número de eventos reales. Ambas probabilidades, observada y esperada, se contrastan mediante una prueba de χ^2 . En este test se debe obtener una significancia mayor de 0,05. Una prueba similar y que da más información sobre la bondad del ajuste consiste en hacer una tabla de contingencia del mismo modo que en la prueba de Hosmer-Lemeshow y a partir de las probabilidades observadas y estimadas realizar un análisis de errores basado en Willmott (1982), tal como se describe en el apartado 3.2, analizando los errores: BIAS, RMSE, RMSES, RMSEU, MAD y MADP. Este fue el análisis escogido para estimar la bondad del ajuste por ser más completo que el test de Hosmer-Lemeshow.

También son muy útiles para estimar la bondad del ajuste las curvas ROC (Receiving Operating Characteristic). Estas curvas representan la sensibilidad frente a (1-especificidad) para un sistema de clasificación binario (Manzo-Delgado et al., 2009). La sensibilidad mide la correcta predicción de los casos con incendio, mientras que la especificidad es la correcta predicción de los casos sin incendio. En la curva ROC cada punto se corresponde con un punto de corte. La línea diagonal que va del punto (0,0) al punto (1,1) representa la ausencia de discriminación del modelo. La bondad de un modelo utilizando las curvas ROC se basa en el área bajo la curva (AUC: Area Under Curve). En el caso de la línea diagonal que va del punto (0,0) al punto (1,1) el área bajo la curva será 0,5, por

tanto cuanto mayor sea este valor, mayor será la capacidad de discriminación del modelo. Esta medida es muy útil y sencilla para comparar distintos modelos.

Finalmente, es importante analizar el porcentaje global de casos clasificados correctamente, así como el porcentaje de casos con y sin evento, por separado, clasificados correctamente. Un porcentaje global de acierto del 50% indicaría predicciones aleatorias, mientras que porcentajes superiores al 50% indican que existe una relación entre las variables independientes y la variable dependiente.

4.2. Aplicación de la regresión logística a la estimación del riesgo de incendio

4.1. Descripción

El objetivo de esta Tesis, como ya se ha mencionado en repetidas ocasiones, es obtener un modelo de predicción de riesgo de incendio incorporando datos de teledetección, en concreto los índices de vegetación. La regresión logística es una técnica muy útil en este sentido, ya que la variable dependiente puede ser dicotómica (presencia o ausencia de incendio) y permite introducir distintas variables independientes. En nuestro caso, la principal variable a introducir es la variación del EVI entre dos periodos consecutivos de 16 días, tras demostrar en el capítulo 3 que dicha variable presenta una relación directa con la frecuencia de incendios.

Además decidimos introducir otras variables relacionadas con el historial de incendios de las distintas cuadrículas y los distintos periodos del año. Estas variables se introducen en forma de pesos variando entre 0 y 1, y son la frecuencia de incendios en cada periodo (peso periodo) y la frecuencia de incendios en cada cuadrícula (peso cuadrícula) calculados a partir de los datos de entrenamiento. De esta forma se espera dar una probabilidad de incendio mayor a las cuadrículas y periodos del año que históricamente presentan una mayor frecuencia de incendios. Debido al distinto patrón de comportamiento anual de los incendios en las dos regiones seleccionadas para el presente estudio (ver figura 3.1), el cálculo de estos pesos se realizó por separado para ambas comunidades. Además, se incluyó una variable categórica para distinguir entre ambas comunidades, de forma que sea posible obtener un modelo único que proporcione resultados distintos según la región de aplicación. Estas variables

pueden estar relacionadas con factores sociológicos (peso cuadrícula y región) y con factores climatológicos (peso periodo).

En un trabajo previo (Bisquert et al. 2010b) centrado en la región de Galicia se comprobó que distinguir entre cuadrículas donde predominan distintos usos de suelo no mejoraba los resultados, por lo que se decidió realizar el análisis sin distinguir usos de suelo (ver apéndice E). En esta Tesis se realiza la distinción entre las regiones de Galicia y Asturias debido a las diferencias observadas en el régimen de incendios, considerando así que estas diferencias se deben a factores sociológicos y no a tipos de vegetación.

De esta forma los datos de entrada al modelo serán: la variación del EVI en dos periodos consecutivos, la frecuencia histórica de incendios en el periodo del año para el cual se pretende obtener el riesgo de incendio, la frecuencia histórica de incendios en la cuadrícula de estudio y la comunidad a la que pertenece dicha cuadrícula. A la hora de aplicar este modelo, las frecuencias de incendios de los distintos periodos y de las distintas cuadrículas deberían de actualizarse cada año, sin embargo la ecuación que se obtenga no necesitará ser modificada. La variable dependiente será la presencia o ausencia de incendio en cada cuadrícula en el periodo de estudio. A diferencia de la metodología del capítulo 3, en este caso, y dado que se incluye la variable periodo del año, se utilizan los datos de todo el año sin necesidad de acotar la época de mayor número de incendios. También hay que reseñar que en esta parte del trabajo no se realizó el filtrado de los casos con incendio previos al periodo de estudio como se hacía en el capítulo 3. Esta decisión fue motivada por la gran cantidad de datos que se eliminaban, haciendo que la aplicación del modelo sea muy restringida y de poca utilidad, y tras comprobar previamente que el tamaño de los incendios en estas regiones es inferior a 1 ha en la gran mayoría de casos, por lo que el efecto sobre el índice de vegetación a una escala de $10 \times 10 \text{ km}^2$ es de escasa importancia.

4.2.2. Resultados

La aplicación de la regresión logística se hizo utilizando el software comercial PASW Statistics 17 (SPSS, 2009).

En la tabla 4.1 se muestran los parámetros del ajuste: α , β , sus errores estándar y su significancia según el test de Wald. Se observa que todas las variables introducidas son estadísticamente significativas ya que presentan una significancia menor de 0,05. Al ser la comunidad una variable categórica, el

parámetro correspondiente a esta variable se introduce en la ecuación como tal, sin multiplicarse por ningún valor, se introduce únicamente el parámetro correspondiente a la región de Asturias, porque la región de Galicia se toma como referencia y por tanto su parámetro es 0. De esta forma la ecuación resultante es la siguiente:

(4.2)

Tabla 4.1. Parámetros del ajuste.

Variable	Parámetro	Error estándar	Sig. (Wald)
V.EVI	-2,5	0,4	< 0,001
Peso Periodo	31,6	0,6	< 0,001
Peso cuadrícula	282	7	< 0,001
Comunidad (Asturias)	-2,66	0,07	< 0,001
Constante	-3,00	0,05	< 0,001

Se observa que el parámetro correspondiente a la comunidad de Asturias toma valor -2,66 que al ser negativo quiere decir que, en las mismas condiciones, la probabilidad de incendio en Asturias es menor que en Galicia y, como se ha comentado previamente, esto debe estar relacionado con factores sociológicos. En el caso de la variación del EVI, el parámetro que lo multiplica es también negativo, con lo cual las variaciones de EVI negativas darán lugar a una probabilidad de incendio mayor que las positivas. En el caso del periodo del año y la cuadrícula, los parámetros son positivos, con lo que la probabilidad de incendio será mayor cuanto mayor sea el valor de estas variables. Todos estos resultados están de acuerdo con los razonamientos previos a la obtención del modelo.

La curva ROC obtenida se muestra en la figura 4.2. El área bajo la curva obtenida en este modelo es de 0,78, siendo éste un valor que indica un buen poder de discriminación por ser significativamente mayor de 0,5.




Figura 4.2. Curva ROC correspondiente al modelo propuesto.

Los porcentajes de acierto obtenidos para los grupos de entrenamiento y de validación por separado se muestran en la tabla 4.2. Para la selección del punto de corte se tuvo en cuenta que el número de casos clasificados sin incendio fuera superior al de casos clasificados con incendio y que el acierto global, el acierto del número de incendios y el acierto de los casos sin incendio estuvieran entorno al 70%. Se seleccionó el punto de corte 0,35.

Tabla 4.2. Clasificación de los casos con y sin incendio y porcentajes de acierto para los grupos de entrenamiento y validación por separado.

Observado	Pronosticado					
	Entrenamiento			Validación		
	Sin incendio	Con incendio	Porcentaje correcto	Sin incendio	Con incendio	Porcentaje correcto
Sin incendio	10412	4389	70	10545	4407	71
Con incendio	2138	5812	73	2355	5416	70
Porcentaje global			71			70

Los resultados aquí obtenidos, porcentajes de acierto y área bajo la curva ROC, se pueden comparar con otros estudios similares en los que se utiliza la regresión logística.

Lozano et al. (2007) utilizan la regresión logística para obtener distintos modelos de riesgo de incendio formados por distintas combinaciones de variables que incluyen índices espectrales de vegetación y de humedad así como una serie de variables estáticas (historial de incendios, variables topográficas). Como variable dependiente utilizan la presencia o ausencia de incendios obtenida a partir de imágenes Landsat. Utilizan un conjunto de datos en el que la mitad de los casos presenta incendio y la otra mitad no. La zona de estudio es el Lago de Sanabria, una zona muy cercana y similar a las zonas de estudio utilizadas en la presente Tesis, y el periodo de estudio es entre los años 1995 y 2002. Obtienen valores del área bajo la curva entre 0,75 y 0,85, y aciertos globales entre el 68% y el 72% con los datos de entrenamiento y entre el 59% y el 63% en los datos de validación. En nuestro caso hemos obtenido un acierto global del 70% tanto en los datos de entrenamiento como en los de validación, y un área bajo la curva de 0,78, utilizando menos variables y un modelo más sencillo.

Schneider et al. (2008) comparan la utilización del VARI y del NDVI para obtener el RG (Relative Greenness, índice de verdor relativo que compara el índice de vegetación en un momento dado con los valores máximo y mínimo históricos) que se utiliza en el FPI (Fire Potential Index). El FPI es un índice de riesgo de incendio utilizado en Estados Unidos que incluye un mapa de modelos de combustible, la humedad del combustible muerto y el RG. Schneider et al. (2008) emplean la regresión logística para validar y comparar el FPI obtenido utilizando el VARI y el NDVI. Como variable dependiente utilizan los incendios detectados por el sensor MODIS. Obtienen un área bajo la curva de 0,69 con el NDVI y de 0,78 con el VARI, sin embargo es posible que exista una sobreestimación del modelo debido a la utilización del producto de incendios de MODIS, ya que este producto no detecta los grandes incendios como tal sino como varios incendios pequeños. Además, en Schneider et al. (2008), al igual que en Lozano et al. (2007), se utiliza para la regresión logística un conjunto de datos que contiene el mismo número de casos con y sin incendio, lo cual es útil en estadística pero no tiene sentido físico. Hay que tener en cuenta que en Schneider et al. (2008) se utilizan otras variables complejas, además de los índices de vegetación, para la obtención del FPI.

En Manzo-Delgado et al. (2009) se combinan distintas variables dinámicas (NDVI y LST) y estáticas (tipo de vegetación, pendiente, elevación y precipitación). Estos autores obtienen un modelo de riesgo de incendio utilizando regresión logística con un acierto del 80% en los datos de entrenamiento pero solo del 69% en los datos de validación. En Manzo-Delgado et al. (2009) los datos de incendios se obtienen a partir de imágenes de satélite (NOAA), acotan el estudio a la época de mayor frecuencia de incendios (Noviembre-Mayo) y utilizan conjuntos de datos con un número similar de casos con y sin incendios, estos dos últimos factores pueden hacer que el modelo funcione mejor que si se utilizara toda la información disponible sin acotar el periodo de estudio, sin embargo la aplicabilidad y fiabilidad de dicho modelo será menor que el modelo presentado en esta Tesis.

En Bisquert et al. (2010c) se comprueba que la utilización de la LST y de las redes neuronales pueden mejorar los resultados, sin embargo en Bisquert et al. (2010c) la única zona de estudio es la región de Galicia donde el elevado número de incendios forestales favorece las estadísticas y facilita que se obtengan mejores resultados.

Para comprobar la bondad del ajuste, además de las curvas ROC, se utilizan unas tablas de contingencia, proporcionadas por el software estadístico PASW17 (SPSS, 2009), que se obtienen dividiendo todos los casos disponibles en 10 grupos iguales en función de las probabilidades de incendio predichas por el modelo (Tabla 4.3). En la figura 4.2 se representa la frecuencia de casos con incendio predicha por el modelo frente a la frecuencia de casos con incendio observadas en cada uno de los intervalos.

A partir de los datos de las tablas de contingencia se llevó a cabo un análisis de errores basado en Willmott (1982), tal y como ya se hizo en el capítulo 3. En la figura 4.2 se observa que existe un buen acuerdo entre los datos observados y los predichos, con pendiente de $0,97 \pm 0,04$, ordenada en el origen de $0,009 \pm 0,004$ y coeficiente de regresión de 0,99. En resumen, el Bias es despreciable, el RMSE es de 0,02, la parte sistemática de éste (RMSES) es 0,007 y la parte no sistemática (RMSEU) es 0,02; el error absoluto es 0,02 y el error absoluto en porcentaje es del 6%.

Tabla 4.3. Tabla de contingencia

Intervalo	Sin incendio		Con incendio		Número total de casos
	Observado	Predicho	Observado	Predicho	
1	2149	2198	126	77	2275
2	2091	2044	184	231	2275
3	2000	1908	275	367	2275
4	1809	1771	466	504	2275
5	1615	1631	660	644	2275
6	1403	1481	872	794	2275
7	1220	1308	1055	967	2275
8	1148	1096	1127	1179	2275
9	867	846	1408	1429	2275
10	499	518	1777	1758	2276

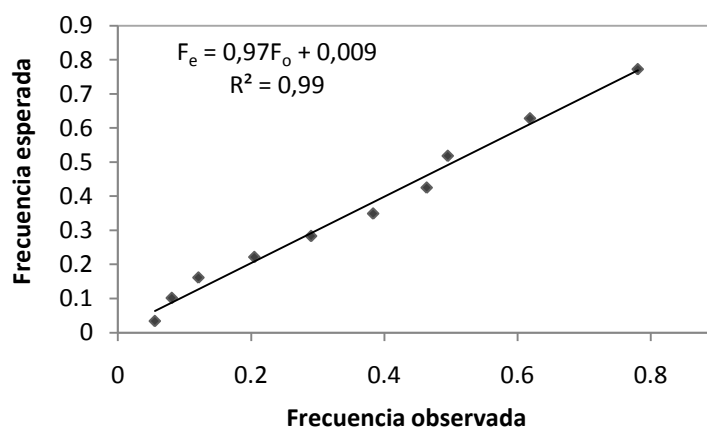


Figura 4.2. Comparación entre la frecuencia de casillas con incendio predicha por el modelo y la frecuencia real de casillas con incendio.

4.3. Niveles de riesgo

En los sistemas operativos de predicción del riesgo de incendio generalmente se utilizan escalas graduadas con distintos niveles de riesgo, de forma que se facilite el trabajo a los encargados de luchar contra los incendios forestales. Estas escalas permiten obtener mapas de riesgo de incendio con

distintos niveles, que generalmente suelen variar entre 3 y 5 categorías diferenciadas. En la presente Tesis se selecciona una escala de 4 niveles, por ser más descriptiva que una escala de 3 niveles y con el fin de que los distintos niveles queden perfectamente definidos y no haya solapamiento entre ellos, es decir, que las probabilidades de incendio sean muy distintas entre ellos. La selección de los niveles se realizó a partir de las probabilidades predichas por la ecuación 4.2, y teniendo en cuenta que el número de casos en cada nivel fuera significativo. La clasificación que mejor se ajustaba a estos criterios es la siguiente:

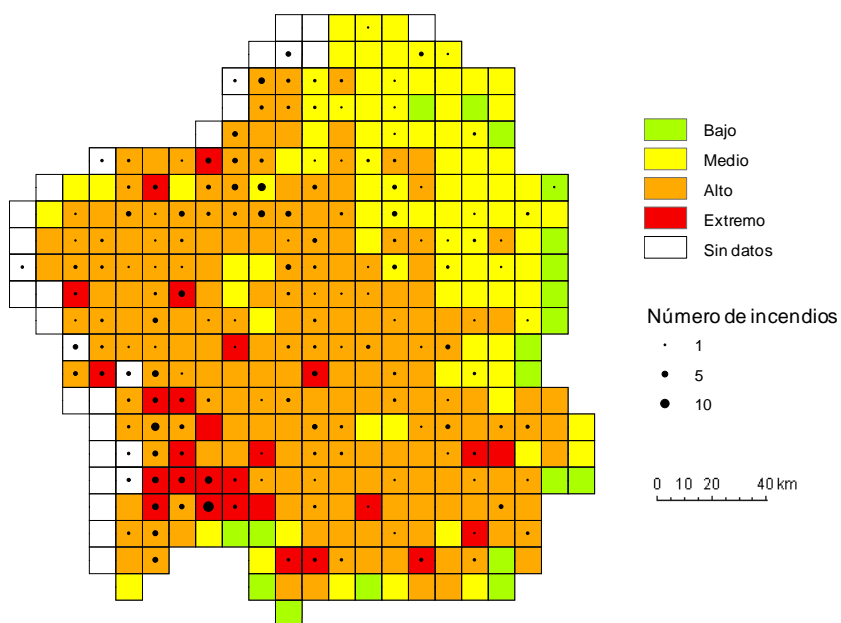
- Riesgo bajo: $P < 21$
- Riesgo medio: $21 \leq P < 32$
- Riesgo alto: $32 \leq P < 52$
- Riesgo extremo: $P \geq 52$

En la tabla 4.4 se muestra el número de casos clasificados en cada nivel y la frecuencia de incendios observada.


Tabla 4.4. Número de casos y frecuencia de incendios en los distintos niveles de riesgo.

Nivel	Número de casos	Número de casos con incendio	Frecuencia de casos con incendio (%)
Bajo	15193	1547	10 ± 5
Medio	8282	2201	27 ± 5
Alto	11028	4761	43 ± 4
Extremo	10970	7211	66 ± 11

En la figura 4.3 se muestra un ejemplo de la aplicación del modelo, en concreto se muestra el mapa de riesgo de incendio predicho para Galicia y para el periodo del 25 de mayo al 9 de junio de 2006 y el mapa de riesgo de Asturias para el periodo del 26 de junio al 11 de julio de 2005. Se ha representado además, superpuesto, el número de incendios que ocurrieron en cada cuadrícula en el periodo correspondiente. Se puede comprobar que en las cuadrículas catalogadas con riesgo bajo o medio hay muy pocos incendios, concentrándose estos en las casillas catalogadas con riesgo alto y extremo.



(a)



(b)

Figura 4.3. Ejemplos de mapas de riesgo para: a) Galicia, en el periodo 25/05 a 09/06 de 2006, y b) Asturias, en el periodo 26/06 a 11/07 de 2005.

4.4. Análisis de resultados por años

Analizando el acierto global año a año por separado para las dos regiones de estudio (tabla 4.5) se observa que en Galicia este acierto ronda siempre el 70%, excepto en el año 2001 cuando se queda en el 63%. En Asturias, es el año 2002 el

que presenta un acierto inferior, sin embargo la diferencia respecto a la media no es tan importante.

Si observamos la frecuencia de incendios por nivel para cada año (tabla 4.6) se comprueba que, aunque existan diferencias para los distintos años y para las dos regiones, siempre se cumple que la menor frecuencia de incendios se obtiene en el nivel bajo y que ésta va aumentando en los siguientes niveles. Sin embargo, se observa que para el año 2001 en Galicia la frecuencia de incendios en el nivel bajo es anormalmente alta, un 26%, lo cual está relacionado también con la disminución del acierto global observado en la tabla 4.5. Para analizar este efecto se ha representado el número de incendios por mes para cada año y el promedio mensual (figura 4.4), observándose que en el año 2001 hubo muchos incendios en los meses de noviembre y diciembre, algo fuera de lo habitual. Además, en la figura 4.5 se han representado las precipitaciones mensuales de cada año y el valor promedio. Se puede comprobar cómo en los meses de noviembre y diciembre las precipitaciones fueron anormalmente bajas, lo cual puede haber dado lugar a ese alto número de incendios en esos meses. Este hecho produce que el acierto disminuya y que la variable época del año tienda a afectar negativamente a los resultados, pero aún así para el año 2001 se obtiene un valor de acierto global del 63%, relativamente bueno. Es en estas condiciones donde la variable variación del EVI puede tener una mayor significancia, puesto que la valiosa información sobre el estado de la vegetación que ofrece la variación del EVI evita que el acierto sea menor.

Tabla 4.5. Aciertos globales para cada año y cada región.

Año	Acierto Galicia (%)	Acierto Asturias (%)
2001	63	76
2002	70	73
2003	75	76
2004	69	77
2005	68	76
2006	70	

Tabla 4.6. Frecuencia de incendios en cada nivel de riegos para los distintos años en Galicia (cursiva), y Asturias.

Año	Bajo	Medio	Alto	Extremo
2001	26,3	30,2	35,3	69,3
	11,4	25,9	33,5	54,8
2002	9,5	30,8	46	73,4
	9,1	20	25	34
2003	2,9	19,8	49,6	73,9
	13,3	32	40,5	63,3
2004	4,7	31,7	56,3	63,6
	12,8	25,2	44,3	57,5
2005	10,7	33,3	44,2	67,6
	13,9	26,2	42,5	56,4
2006	3,2	16,8	33,6	59,3




Figura 4.4. Precipitación mensual en mm para los distintos años en Galicia.




Figura 4.5. Número de incendios mensual para los distintos años en Galicia.

4.5. Resumen

En este capítulo se ha utilizado la variación del EVI como base para establecer un modelo de riesgo de incendios. Se ha empleado la regresión logística como técnica estadística para definir dicho modelo, por ser ésta una técnica de predicción que proporciona la probabilidad de ocurrencia de un evento (variable dependiente dicotómica) a partir de una o más variables predictoras o independientes que pueden ser variables continuas o categóricas. Además de la variación del EVI, se han utilizado otras dos variables continuas relacionadas con la frecuencia de incendios en cada cuadrícula y en cada periodo del año, y una variable categórica que distingue entre las dos zonas de estudio, Galicia y Asturias. Definiendo un punto de corte, el modelo clasificará cada caso en presencia o ausencia de incendio. Se utilizan la mitad de los casos disponibles para entrenar el modelo y la otra mitad para validar. Con las cuatro variables independientes disponibles se ha construido un modelo de riesgo de incendio que clasifica correctamente el 70% de los casos del estudio, tanto en el conjunto de entrenamiento como en el de validación. En un análisis más detallado (Willmott, 1982) se obtienen una serie de errores estadísticos que muestran la bondad del ajuste, al representar los valores esperados y observados se obtiene una ecuación

con pendiente muy cercana a la unidad y ordenada en el origen prácticamente nula, el error cuadrático medio es 0,2 y el error absoluto es del 6%.

A partir de las probabilidades de incendio predichas por el modelo se definen 4 niveles de riesgo que facilitarán las tareas de prevención y extinción, permitiendo elaborar mapas de riesgo cada 16 días en los que se distinguen claramente las zonas de mayor y menor riesgo de incendio.

Capítulo 5

Conclusiones

A modo de resumen de lo expuesto en la presente Memoria, resaltamos las siguientes conclusiones:

1. Se ha descrito un procedimiento detallado para relacionar la variación de los índices de vegetación entre dos periodos consecutivos de 16 días, obtenidos a partir de imágenes de satélite, y la frecuencia de incendios del periodo posterior. Se ha descrito el procesado de las imágenes de dos productos del sensor MODIS que proporcionan directamente los índices de vegetación EVI y NDVI (MOD13Q1) o las reflectividades espectrales necesarias para su cálculo (MOD09A1). Dicho procesado incluye los siguientes pasos: filtrado de datos erróneos, rellenado de huecos y rescalado de las imágenes a la escala adecuada para el estudio.
2. Se ha analizado la relación entre distintos índices de vegetación (EVI, NDVI, VARI, GEMI, GVMI, SAVI, NDII, NDWI) y la frecuencia de incendios en las regiones de Galicia y Asturias. El análisis se ha hecho por separado para las dos regiones con el fin de comprobar si un mismo índice era válido para distintas zonas. Se ha comprobado que únicamente la variación temporal de tres de estos índices (EVI, GEMI y SAVI), en ambas regiones, presenta una relación directa con la frecuencia de incendios. Se observa una relación lineal con coeficiente de regresión de 0,8 para los tres índices.
3. Para decidir cuál de los tres índices anteriores (EVI, GEMI y SAVI) es el más adecuado, es decir, presenta una relación más directa con la frecuencia de incendios, se ha llevado a cabo una validación consistente en aplicar las ecuaciones obtenidas a un conjunto de datos reservados para tal fin. En ambas regiones el índice de vegetación cuya variación presenta una mayor relación con la frecuencia de incendios es el EVI (Enhanced Vegetation Index) proporcionado por el producto MOD13Q1 del sensor MODIS, obteniéndose un error absoluto del 11% en Galicia y del 15% en Asturias.

4. Se ha utilizado la regresión logística para combinar la variación del EVI con otros parámetros por ser ésta una técnica estadística muy útil en los estudios de clasificación con variables dependientes dicotómicas, en este caso, presencia o ausencia de incendio. Mediante esta técnica se ha obtenido un modelo de riesgo de incendio.

5. Los parámetros con los que se ha combinado la variación del EVI son: el historial de incendios de cada zona, el historial de incendios de cada periodo del año, y la comunidad (Galicia o Asturias). El modelo propuesto presenta un acierto global del 70% tanto en los datos utilizados para entrenar el modelo como en los datos utilizados para validarlo.

6. La bondad del ajuste se ha analizado de distintas maneras, por un lado se ha dibujado la curva ROC y se ha obtenido un área bajo la curva de 0,78, indicando este valor que el clasificador obtenido es muy bueno. Además se ha realizado un análisis detallado de errores estadísticos a partir de una tabla de contingencias entre los valores observados y predichos por el modelo, obteniéndose un error absoluto en la probabilidad de incendio del 6%.

7. A partir de las probabilidades de incendio predichas por el modelo se ha definido una escala de riesgo de incendio que consta de cuatro niveles y que permite obtener mapas de riesgo cada 16 días. Las probabilidades de que ocurra un incendio en cada nivel son: 10%, 27%, 43% y 66% para los niveles bajo, medio, alto y extremo.

Bibliografía

- Annoni, A., Perdigao, V. (1997). Technical and methodological guide for updating CORINE Land Cover data base. *European Commission, EUR 17288EN*. Ispra, Italy: Space Application Institute of Joint Research Centre.
- Bisquert, M.M., Sánchez, J.M., Caselles, V., Paz Andrade, M.I., Legido, J.L., (2009). Assessment of spectral indices derived from MODIS data as fire risk indicators in Galicia. *Proceedings of the VII International EARSeL Workshop, Matera (Italy), 2-5 September 2009*, 109-113.
- Bisquert, M., Sánchez, J.M., Caselles, V. (2010a). Vegetation indices as fire risk estimators using MODIS images. *International Journal of Applied Earth Observation and Geoinformation*, en revisión.
- Bisquert, M.M., Sánchez, J.M., Caselles, V. (2010b). Fire danger estimation from MODIS Enhanced Vegetation Index data. Application to Galicia region (northwest Spain). *International Journal of Wildland Fire*, In press.
- Bisquert, M., Caselles, E., Sánchez, J.M., Caselles, V., Rubio, E., (2010c). application of artificial neural networks to the prediction of forest fire danger using MODIS data. *RAQRS*.
- Bossard, M., Feranec, J., Otahel, J. (2000). CORINE Land Cover Technical Guide – Addendum 2000. European Environment Agency.
- Burgan, R., Claver, R.W., & Claver, J.M. 1998. Fuel models and fire potential from satellite and surface observation. *International Journal of Wildland Fire*, 8, 159-170.
- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., Tarantola, S. (2002). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1. Theoretical approach. *Remote Sensing of Environment*, 82, 188-197.
- CLIF (Comité de Lucha contra los Incendios Forestales), 2006. Apuntes para la codificación en oficina del Parte de Incendio Forestal. *Ministerio de Medio Ambiente*.
- Cheng, Y., Zarco-Tejada, P.J., Riaño, D., Rueda, C.A., Ustin, S.L., 2006. Estimating vegetation water content with hyperspectral data for different canopy scenarios: Relationships between AVIRIS and MODIS indexes. *Remote Sensing of Environment*, 105, 354-366.

- Chuvienco, E. (2008). Teledetección Ambiental, 3ª Edición. *Ariel*.
- Chuvienco, E., Cocero, D., Aguado, I., Palacios, A., Prado, E., 2004a. Improving burning efficiency estimates through satellite assessment of fuel moisture content. *Journal of Geophysical Research*, 109, D14S07.
- Chuvienco, E., Aguado, I., Dimitrakopoulos, P., 2004. Conversion of fuel moisture content values to ignition potential for integrated fire danger assessment. *Canadian Journal of Forest Research*, 34, 2284-2293.
- Gao, X. (1996). NDWI – A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. *Remote Sensing of Environment*, 58, 257-266.
- Gao, X, Huete, A., Didan, K. (2003). Multisensor Comparisons and Validation of MODIS Vegetation Indices at the Semiarid Jornada Experimental Range. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 10, 2368-2381.
- Gilabert, M.A., González-Piqueras, J., García-Haro, J. (1997). Acerca de los índices de vegetación. *Revista de Teledetección*, 8.
- Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D. (2002). Novel algorithms for remote sensing of vegetation fraction. *Remote Sensing of Environment*, 80, 76-87.
- González-Alonso, F., Cuevas, J.M., Casanova, J.L., Calle, A., Illera, P. (1997). A forest fire risk assessment using NOAA AVHRR images in the Valencia area, eastern Spain. *International Journal of Remote Sensing*, 18 (10), 2201-2207.
- Hardisky, M.A., Klemas, V., Smart, R.M. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49, 1, 77-83.
- Huete, A. (1988). A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25, 295-309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G. (2002). Overview of the radiometric and biophysical performance of the MODIS Vegetation Indices. *Remote Sensing of Environment*, 83, 195-213.

- Huete, A., Justice, C. & Van Leeuwen, W. (1999). MODIS Vegetation Index (MOD 13). *Algorithm Theoretical Basis Document Version 3*. NASA Goddard Space Flight Center, Greenbelt (MD), USA.
- INE (Instituto Nacional de Estadística). Citado en Diciembre de 2010.
<http://www.ine.es/jaxi/tabla.do?path=/t43/a012/a1998/l0/&file=t20015b.px&type=pcaxis&L=0>
- Jackson, R.D., Slater, P.N., Pinter, P.J. (1983). Discrimination of growth and water stress in wheat by various vegetation indices through clear and turbid atmospheres. *Remote Sensing of Environment*, 13, 187-208.
- Jacquemoud S & F Baret, 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sensing of Environment*, 34, 75-91.
- Lozano, F.J., Suárez-Seoane S., de Luis, E. (2007). Assessment of several spectral indices derived from multi-temporal Landsat data for fire occurrence probability modeling. *Remote Sensing of Environment*, 107, 533-544.
- Maki, M., Ishihara, M., Tamura, M. (2004). Estimation of leaf water status to monitor the risk of forest fires by using remotely sensed data. *Remote Sensing of Environment*, 90, 441-450.
- Manzo-Delgado, L., Sánchez-Colón, S., Álvarez, R. (2009). Assessment of seasonal forest fire risk using NOAA-AVHRR: a case study in central Mexico. *International Journal of Remote Sensing*, 30, 19, 4991-5013.
- Maselli, F., Romanelli, S., Bottai, L., Zipoli, G. (2003). Use of NOAA-AVHRR NDVI images for the estimation of dynamic fire risk in Mediterranean areas. *Remote Sensing of Environment*, 86, 187-197.
- Ministerio de Medio Ambiente (2006). Los incendios forestales en España. Decenio 1996-2005.
- Ministerio de Medio Ambiente y Medio Rural y Marino (1997). Segundo Inventario Forestal Nacional.
- Pinty, B., Verstraete, M.M. (1992). GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetatio*, 101, 15-20.
- Rothermel, R.C., (1972). A mathematical model for predicting fire spread in wildland fuels. *USDA Forest Service Research Paper*, INT-115.

- Rouse, J.W., Hass, R.H., Schell, J.A., Deering, D.W., (1974). Monitoring vegetation systems in the Great Plains with ERTS. *Proceedings, third Earth Resources Technology Satellite-1 Symposium, Greenbelt, NASA SP-351* (pp. 309-317).
- Sánchez, J.M., Rubio, E., López-Serrano, F.R., Caselles, V., Bisquert, M.M., (2009). Effects of fire on surface energy fluxes in a central Spain mediterranean forest. Ground measurements and satellite monitoring. *Proceedings of the VII International EARSeL Workshop, Matera (Italy), 2-5 September 2009*, 145-149.
- Schneider, P., Roberts, D.A., Kyriakidis, P.C. (2008). A VARI-based relative greenness from MODIS data for computing the Fire Potential Index. *Remote Sensing of Environment*, 112, 1151-1167.
- Solano, R., Didan, K., Jacobson, A., Huete, A., (2010). MODIS Vegetation Indices (MOD13) C5 User's Guide. Version 1.00. Terrestrial Biophysics and Remote Sensing Lab, University of Arizona.
- SPSS Inc. (2009). PASW STATISTICS 17.0 Command Syntax Reference. SPSS Inc., Chicago.
- Stow, D., Niphadkar, M., Kaiser, J. (2005). MODIS-derived visible atmospherically resistant index for monitoring chaparral moisture content. *International Journal of Remote Sensing*, 26, 17, 3867-3873.
- Verbesselt J, Jönsson P, Lhermitte S, Van Aardt J, Coppin P (2006) Evaluating satellite and climate data-derived indices as fire risk indicators in savanna ecosystems. *IEEE Transactions on Geosciences and Remote Sensing* **44**, 1622-1632.
- Verhoef W, 1984. Light Scattering by Leaf Layers with Application to Canopy Reflectance Modeling: The SAIL model. *Remote Sensing of Environment*, 125-141.
- Vermote, E.F., Vermoulen, A. (1999). MODIS. Algorithm Technical Background Document. Atmospheric Correction Algorithm: Spectral Reflectances (MOD09). NASA contract NAS5-96062.
- Vermote, E.F., Kotchenova, S.Y., Ray, J.P., (2008). MODIS Surface Reflectance User's Guide. Version 1.2. MODIS Land Surface Reflectance Science Computing Facility.

Willmott, C.J. (1982) Some comments on the evaluation of model performance. *American Meteorological Society*, 63, 11, 1309-1313.

Yebra, M., Chuvieco, E., Riaño, D. (2008). Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and forest meteorology*, 148, 523-536.

Anexo A

Bandas de MODIS

BAND #	RANGE nm	RANGE μm	KEY USE
	reflected	emitted	
1	620-670		Absolute Land Cover Transformation, Vegetation Chlorophyll
2	841-876		Cloud Amount, Vegetation Land Cover Transformation
3	459-479		Soil/Vegetation Differences
4	545-565		Green Vegetation
5	1230-1250		Leaf/Canopy Differences
6	1628-1652		Snow/Cloud Differences
7	2105-2155		Cloud Properties, Land Properties
8	405-420		Chlorophyll
9	438-448		Chlorophyll
10	483-493		Chlorophyll
11	526-536		Chlorophyll
12	546-556		Sediments
13h	662-672		Atmosphere, Sediments
13l	662-672		Atmosphere, Sediments
14h	673-683		Chlorophyll Fluorescence
14l	673-683		Chlorophyll Fluorescence
15	743-753		Aerosol Properties
16	862-877		Aerosol Properties, Atmospheric Properties
17	890-920		Atmospheric Properties, Cloud Properties
18	931-941		Atmospheric Properties, Cloud Properties
19	915-965		Atmospheric Properties, Cloud Properties
20		3.660-3.840	Sea Surface Temperature
21		3.929-3.989	Forest Fires & Volcanoes
22		3.929-3.989	Cloud Temperature, Surface Temperature
23		4.020-4.080	Cloud Temperature, Surface Temperature
24		4.433-4.498	Cloud Fraction, Troposphere Temperature
25		4.482-4.549	Cloud Fraction, Troposphere Temperature
26	1360-1390		Cloud Fraction (Thin Cirrus), Troposphere Temperature

Anexo A

27		6.535-6.895	Mid Troposphere Humidity
28		7.175-7.475	Upper Troposphere Humidity
29		8.400-8.700	Surface Temperature
30		9.580-9.880	Total Ozone
31		10.780-11.280	Cloud Temperature, Forest Fires & Volcanoes, Surface Temp.
32		11.770-12.270	Cloud Height, Forest Fires & Volcanoes, Surface Temperature
33		13.185-13.485	Cloud Fraction, Cloud Height
34		13.485-13.785	Cloud Fraction, Cloud Height
35		13.785-14.085	Cloud Fraction, Cloud Height
36		14.085-14.385	Cloud Fraction, Cloud Height

Anexo B

Banda de calidad del producto MOD13Q1

Bit	Long name	Value	Key
0-1	MODLAND_QA	00	Produced, good quality
		01	VI produced, but check other QA
		10	Pixel produced, but most probably cloudy
		11	11 Pixel not produced due to other reasons than clouds
2-5	VI usefulness	0000	Highest quality
		0001	Lower quality
		0010	Decreasing quality
		0100	Decreasing quality
		1000	Decreasing quality
		1001	Decreasing quality
		1010	Decreasing quality
		1100	Lowest quality
		1101	Quality so low that it is not useful
		1110	L1B data faulty
1111	Not useful for any other reason/not processed		
6-7	Aerosol quantity	00	Climatology
		01	Low
		10	Average
		11	High
8	Adjacent cloud detected	1	Yes
		0	No
9	Atmosphere BRDF correction	1	Yes
		0	No
10	Mixed Clouds	1	Yes
		0	No
11-13	Land/Water Mask	000	Shallow ocean
		001	Land (Nothing else but land)
		010	Ocean coastlines and lake shorelines
		011	Shallow inland water
		100	Ephemeral water
		101	Deep inland water
		110	Moderate or continental ocean
		111	Deep ocean
14	Possible snow/ice	1	Yes
		0	No
15	Possible shadow	1	Yes
		0	No

Fuente: Solano et al. (2010).

Anexo C

Banda de calidad del producto MOD09A1

Bit	Long name	Value	Key
0-1	Cloud state	00	Clear
		01	Cloudy
		10	Mixed
		11	Not set, assumed clear
2	Cloud shadow	0	No
		1	Yes
3-5	Land/water flag	000	Shallow ocean
		001	Land
		010	Ocean coastlines and lake shorelines
		011	Shallow inland water
		100	Ephemeral water
		101	Deep inland water
		110	Continental/moderate ocean
		111	Deep ocean
6-7	Aerosol quantity	00	Climatology
		01	Low
		10	Average
		11	High
8-9	Cirrus detected	00	None
		01	Small
		10	Average
		11	High
10	Internal cloud algorithm flag	1	Cloud
		0	No cloud
11	Internal fire algorithm flag	1	Fire
		0	No fire
12	MOD35 snow/ice flag	1	Yes
		0	No
13	Pixel is adjacent to cloud	1	Yes
		0	No
14	BRDF correction performed	1	Yes
		0	No
15	Internal snow algorithm flag	1	Yes
		0	No

Fuente: Vermote et al. (2008)

Anexo D

Artículo “Vegetation indices as fire risk indicators using MODIS images.”

El presente estudio está en revisión en la revista International Journal of Applied Earth Observation and Geoinformation. Esta revista tiene un factor de impacto de **1,8** y ocupa la posición 6 de las 21 revistas de la categoría de “Teledetección” indexadas en el ISI-Journal of Citation Reports Science Edition 2009.

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63

1 **VEGETATION INDICES AS FIRE RISK INDICATORS USING MODIS IMAGES.**

2

3 Mar Bisquert Perles^a, Juan Manuel Sánchez Tomás^b, Vicente Caselles Miralles^a

4 ^aDepartment of Earth Physics and Thermodynamics, Faculty of Physics, University of Valencia, Doctor
5 Moliner, 50, 46100 Burjassot, Valencia, Spain

6 María.Mar.Bisquert@uv.es

7 ^bApplied Physics Department, School of Industrial Engineering, University of Castilla-La Mancha, Av.
8 España s/n, 02071, Albacete, Spain

9

10 **ABSTRACT**

11 Forest fires are very dangerous for nature, including vegetation, animals, soils, etc., especially
12 when they are recurrent. In areas such as Galicia (Spain), forest fires are frequent and
13 devastating. For these reasons, prevention tasks and development of fire risk models become
14 very important.

15 Vegetation and moisture indices can be used to monitor the vegetation status; however the
16 different indices do not work the same in different vegetation species. In this paper, we
17 selected eight different spectral indices in order to determine the most appropriate index in
18 Galicia. This study was extended to the adjacent region of Asturias. Six years of images from
19 the MODIS (Moderate Resolution Imaging Spectroradiometer) products MOD09A1 and
20 MOD13Q1, together with ground fire data in a 10x10 km grid basis were used. The percentage
21 of fire events fits the variations suffered by some of the spectral indices, following a linear
22 distribution in both, Galicia and Asturias. The Enhanced Vegetation Index (EVI) seems to be the
23 most appropriate index, with an estimation error of the fire probability ranging between 11%
24 in Galicia and 18% in Asturias. Based on these results we established a three level risk
25 classification. This work is a step forward in the labour of contributing to improve the

26 efficiency of the fire prevention systems currently in use, by the application of remote sensing
27 techniques.

28

29 **1. INTRODUCTION AND OBJECTIVES**

30 Forest fires are a highly destructive phenomenon for nature. Fire effects are not limited to
31 vegetation, but also affect the soil, causing its degradation and erosion (Martin et al., 2009),
32 the diversity of species (Lozano et al., 2007) and even human lives. They are also an important
33 source of CO₂ and other greenhouse gases (Palacios-Orueta et al., 2005).

34 In Spain, according to statistics from the Ministry of Environment, an average number of
35 20,887 fires per year were registered during the period 1996-2005, of which approximately
36 60% were deliberate. Besides, the average forested area burned reached 123,459 ha per
37 year. Galicia region is an area particularly affected by the devastating effects of forest fires.
38 Around 50% of all fires in Spain take place in Galicia, while in the adjacent region of Asturias
39 only 8% occurs. Focusing on forest landcover, burned forest extension in Galicia represents
40 25% of the total in Spain, and 9% in the case of Asturias.

41 Prevention is essential in the fight against fire. Different models provide fire risk indices based
42 on the combination of different variables such as weather data, fire history, proximity to roads
43 and/or people, etc., (Castro et al., 2003; Alonso-Betanzos et al., 2003, Aguado et al., 2007).
44 However, field measurements are sometimes required, which is very costly in economic terms,
45 time and human resources. Remote sensing techniques facilitate these tasks. They have been
46 already used in many studies with the aim of obtaining parameters required in fire hazard
47 models (Sebastián-López et al., 2002; Chuvieco et al., 2004, Maki et al., 2004, Lozano et al.,
48 2008).

49 Several studies have demonstrated the existence of a relationship between fire and vegetation
50 conditions (Schneider et al., 2008, Lozano et al., 2007 and 2008). In particular, the vegetation
51 water content is a key factor in the generation and spread of fires (Maki et al., 2004). The most

52 widely used parameter for characterization of vegetation moisture content is the FMC (Fuel
53 Moisture Content). However, the measure of this parameter requires field measurements,
54 limiting then its direct application to fire prediction. Remote sensing techniques offer viable
55 alternatives to field measurements. The vegetation has a characteristic spectral curve when
56 healthy, presenting a relative maximum in the green band (0.495 – 0.57 μm), a minimum in the
57 red band (0.62 – 0.75 μm) and a maximum in the near infrared (0.750 – 1.3 μm). This curve
58 changes with different factors, such as moisture, chlorophyll content, the structure of the
59 plant, etc. In the middle infrared area (1.3 – 2.5 μm) of the electromagnetic spectrum, there
60 are three water absorption bands centered at 1.4 μm , 1.9 μm and 2,5 μm . Reflectance in these
61 bands increases with decreasing FMC. However, a decrease in water content affects the
62 chlorophyll amount in the plant and the internal structure of leaves, and hence the
63 photosynthetic activity and the spectral response of the vegetation, resulting in a decrease in
64 reflectance in the green band and near infrared and an increase in the red band. These
65 differences in the spectral curves of healthy vegetation and vegetation with some deficiency
66 can be characterized by measuring its reflectivity from satellite by combination of different
67 visible and near infrared bands. Numerous studies have related the FMC with satellite data
68 (Dennison et al., 2005, Stow et al., 2005), especially using indices involving middle infrared
69 bands. Furthermore, some studies have shown that vegetation indices can be used directly to
70 characterize the water status of the vegetation (Yebra et al., 2008, Cheng et al., 2006). In some
71 papers, vegetation indices have been shown useful as fire risk indicators (Chuvienco et al., 2004,
72 Maselli et al., 2003). However, each study yields different conclusions regarding the most
73 appropriate vegetation index to be used for fire risk estimation. The reason is that the spectral
74 response of vegetation, according to the moisture content, can vary depending on the species.
75 Therefore the best index accounting for the changes in vegetation status, and better
76 representing then the relationship between the vegetation status and fires must be
77 determined for each study site. Yebra et al. (2008), conducted a study to find the best index to

78 characterize the FMC in an area of grassland and another of shrubs. These authors showed
79 that indices based on red/near infrared (EVI: Enhanced Vegetation Index, NDVI: Normalized
80 Difference Vegetation Index, SAVI: Soil Adjusted Vegetation Index) provided better results in
81 grassland areas, while those based on near infrared and middle infrared (NDII: Normalized
82 Difference Infrared Index, GVM: Global Vegetation Moisture Index NDWI: Normalized
83 Difference Water Index) worked better in shrubland areas. Cheng et al. (2006) compared
84 different spectral indices in a crop and shrubs area, and a conifer forest. Best results were
85 obtained using EVI in the first zone and NDWI in the second one.
86 The objective of this work is to select a parameter indicator of the vegetation condition,
87 obtained from remote sensing techniques, which could be included in more complete fire
88 danger systems. With this aim a comprehensive study is carried out, comparing different
89 spectral indices, rescued from the literature, as fire risk indicators in the Spanish regions of
90 Galicia and Asturias.

91

92 **2. STUDY AREA AND DATASET**

93 Galicia and Asturias cover an area of 29,575 km² and 10,604 km², respectively. About 70% of
94 the surface of both regions is forestry, according to the Second National Forest Inventory. In
95 Galicia coniferous forests (especially pinus pinaster) are predominant, but there is also a very
96 important population of hardwoods such as oak, white eucalyptus and common chestnut. In
97 Asturias hardwood forests are more abundant, mainly formed by common chestnut, beech
98 and oak, but there are also populations of conifers (pinus pinaster, red pine and Californian
99 pine). In both regions there are also large areas of grasslands. Climate in these regions is humid
100 due to the west prevailing winds bringing moist air masses, and temperatures are mild.
101 Agencies fighting forest fires work on the basis of a grid that divides Spain in 10x10 km cells,
102 based on the UTM (Universal Transverse Mercator) projection. The historical series of forest

103 fires in Spain are based on this grid. For this reason the vegetation status is characterized with
104 the same spatial resolution.

105 For the present study images from MODIS sensor onboard TERRA satellite were used. In
106 particular products MOD13Q1 and MOD09A1 were selected. MOD13Q1 is a composite of 16
107 day images containing processed NDVI and EVI data at 250m spatial resolution. MOD09A1 is a
108 composite of 8 images containing reflectances in seven different spectral bands at 500m
109 spatial resolution, these reflectances were used in order to obtain the different indices
110 selected for the study. MODIS images were provided by the NASA Land Processes Distributed
111 Active Archive Center (LPDAAC), covering a 6-years period, from 2001 to 2006. By using
112 composite images, problems related to clouds presence (frequent in these regions) can be
113 mitigated since only cloud-free values (based on the quality band included in each MODIS
114 product) are assigned to each particular pixel.

115

116 **3. METHODOLOGY**

117 This paper presents a comparison of eight different spectral indices as fire risk indicators. The
118 spectral response to changes in the vegetation differs depending on the index.

119 The methodology can be divided in four parts: i) selection of the study period, ii) processing of
120 MODIS images, iii) calculation of the different spectral indices, and iv) search for empirical
121 relationships between the changes experienced by the indices and the fire frequency in each
122 cell.

123 **3.1. Study period**

124 Figure 1 shows the histogram of the average value of fire ignitions for the study period. Most
125 fires in Galicia are concentrated between the months of February and the first half of October,
126 while in Asturias the second half of October is also important, so the study was restricted to
127 these periods. The seasonal behavior of the fires is also different in the two regions. In both
128 cases there are two fire peaks, one in March and another in summer. However, in Asturias the

129 peak centered in March is more important than the one in summer, while in Galicia the most
130 important peak is the one in summer. The number of fire ignitions is much higher in Galicia
131 than in Asturias. Some difficulties may arise from this fact when searching for relationships in
132 Asturias, due to the limited statistics. For all these reasons, the study was conducted
133 separately in each region.

134 **Insert Figure 1.**

135 **3.2. MODIS image processing**

136 MOD09A1 product images are the result of an 8-day composition with a spatial resolution of
137 500 m compared to the 16-day composition and the 250 m of the MOD13Q1 images. The
138 composition of several days allows for greater spatial coverage minimizing the effects of
139 clouds. Nevertheless, pixels with no-reliable information due to the presence of clouds, sensor
140 errors, etc. were still present. Thus, a filtering process was carried out to remove those pixels
141 from the study. Firstly, a filter based on the information contained in the quality band,
142 provided in each product, was obtained. Pixels containing clouds, shadows or snow were
143 removed. On the other hand, a mask of water bodies (oceans, rivers and lakes) and large cities
144 was created, from information of the Corine Land Cover 2000.

145 A special treatment was needed for some of the MOD09 images, specifically for band 5, due to
146 the presence of noise. The MODIS band 5 (centered at 1,24 μm) is a water absorption band,
147 which is important to characterize the water status of vegetation and is used in one of the
148 most common indices for the estimation of vegetation moisture, NDWI (Normalized Difference
149 Water Index), so it was important to deal with the noise problem of this band. This noise (in
150 form of diagonal lines) was easily noticeable since the pixels affected showed values
151 significantly larger than those surrounding. A 3x3 pixel matrix was created and applied along
152 the entire image. This matrix calculated the difference between the value of each pixel and the
153 average value of the surrounding pixels. If this difference exceeded a preset threshold, the
154 central pixel was considered wrong pixel. A new mask was created with the wrong pixels.

155 After, a filling process was carried out to assign a value to those pixels or small groups of pixels
156 previously masked. This filling process consisted of applying a 5x5 pixel matrix to those pixels
157 classified as erroneous or no data. This matrix assigned to the central pixel the average value
158 of the surrounding pixels with valid information. Then a composition of two consecutive
159 images was performed with the aim of obtaining an image every 16 days. Average values were
160 considered for those pixels containing information in both images, whereas the single value of
161 one of them was assigned to the compositing image when missing information in the other
162 image. Although the product MOD09A1 provides data with 8-day frequency, we decided to
163 keep working at the 16 days scale because a decline in the vegetation index over a longer
164 period is more significant for the fire prediction. Moreover, given the climate of the area, the
165 product MOD09A1 presented many cloud problems. Finally the 10x10 km grid was
166 superimposed and average value of all pixels with information contained in each cell was
167 calculated when the cell was occupied by at least 10% of land pixels and 80% of the pixels
168 contained valid information . When working with a resolution of 10x10 km some detailed
169 information may be lost, but doing so is necessary to match the information of the vegetation
170 with the number of fires.
171 MOD13Q1 images are provided with a temporal resolution of 16 days and without noise
172 problems, so only the filtering, filling and cell averaging processes are needed.

173 **3.3. Obtaining the spectral indices**

174 The spectral indices chosen for the study are listed in Table 1. This compilation was based on
175 several studies (Maki et al., 2004, Stow et al., 2005, Dennison et al., 2005; Verbesselt et al.,
176 2006, Cheng et al., 2006; Yebra et al., 2008) in which these indices had been used to
177 characterize the water status of the vegetation or to obtain a fire risk index. Vegetation indices
178 are different combinations of the visible and/or infrared bands, in particular the MODIS bands
179 used in this work are: band 1 (620-670nm), band 2 (841-876nm), band 3 (459-479nm), band 4
180 (545-565nm), band 5 (1230-1250nm) and band 6 (1628-1652nm).

181 Most studies are applied to grassland and shrubland areas, showing that near-infrared and
182 middle infrared indices (NDII, GVMI, NDWI) represent better the water status of vegetation in
183 shrubland areas. (Yebera et al. 2008, Dennison et al., 2005). However, Maki et al. (2004) in a
184 conifer area, concluded that the NDWI can be used to obtain the humidity, but the amount of
185 vegetation is also needed to estimate the fire risk, and they used the NDVI with this aim.
186 However, the presence of dense vegetation in our study areas saturates some indices such as
187 NDVI. Under these conditions NDVI does not represent properly the changes in the vegetation
188 status. Moreover, the NDVI is affected by the contributions of soil and atmosphere. The SAVI
189 was defined in order to avoid soil contributions. This index is a modification of the NDVI and
190 includes a parameter related to the amount of vegetation. GEMI and VARI indices were
191 designed to remove atmospheric disturbances, and the EVI takes into account both effects, soil
192 contributions and atmospheric disturbances.

193 **Insert Table 1.**

194 **3.4. Relationship between fire frequency and changes in the spectral indices**

195 A vegetation index variation between two dates indicates the increase or decrease in
196 vegetation greenness, which is related to plant water status. Based on the idea that fire risk is
197 greater in areas and periods of drought, index changes between two periods of 16 days were
198 fitted to the frequency of fires in the next period.

199 The process is repeated for all the indices. First, the difference between two consecutive
200 images is obtained. Then, cells are grouped in intervals of 0.01 in index variation, and fire-
201 affected cells are counted in each interval. To avoid non-realistic index variations produced by
202 a fire event, the database was filtered, removing those cells in which a fire ignition had been
203 registered during the two weeks prior the study period, since a fire would yield a significant
204 decrease in the vegetation index. The frequency of fires is obtained as the ratio between the
205 number of fire-affected cells and the total number of cells in each interval. By representing the

206 fire probability (frequency of fire-affected cells) versus the index variations, the eventual
207 relationship between these two parameters can be obtained.

208 50% of the time series (randomly selected) was used to obtain the relationship, which was
209 further validated using the other 50%.

210 **4. RESULTS AND DISCUSSION**

211 Good adjustment is shown between observed and estimated fire probabilities in three of the
212 indices used. An increasing tendency of fire frequency is observed when the value of the
213 indices decreases (figure 2). A decrease in the indices is an indicator of the plant health, when
214 the plant does not have enough water or nutrients it becomes yellowish and the vegetation
215 index decreases. Under these conditions the vegetation is more vulnerable to fire ignition. A
216 linear relationship is observed between their variations and the fire frequency for the
217 following indices: EVI, GEMI and SAVI, inferred using reflectances from product MOD09 and
218 EVI directly given by product MOD13. The rest of the indices in Table 1 did not show significant
219 correlation with fire frequency (see figure 3).

220 According to Maki et al. (2004) we observed that moisture-related indices did not show a clear
221 relationship with the fire probability. One might think that the noise problem in band 5 could
222 be related to poor results when using the NDWI, however this is not the case since the filling
223 process was also applied to cloudless pixels and differences between the original pixel value
224 and the value assigned by the filling process were lower than 0.1 in more than 90% of cases.

225 Thus, the impact is not significant since each cell contains about 400 pixels. In addition none of
226 the indices including water absorption bands are shown good indicators of fire risk in Galicia.

227 As far as the vegetation indices, in areas such as Galicia and Asturias, where the forests are
228 predominated by tall trees, atmospheric disturbances will be more important than soil
229 contributions. In fact we showed the GEMI and EVI as the indices that best characterize the
230 state of vegetation. According to this reasoning, VARI would be expected to offer similar
231 results to GEMI and EVI, however, this index was defined in a wheat area very different from

232 the vegetation of Galicia and Asturias. Thus it is not surprising that VARI is not a good index to
233 characterize the vegetation state in our study areas. Moreover, note that the proposed
234 methodology is based on the variations of the indices, as a difference with literature where
235 usually the index value itself is used, which can lead to different conclusions.
236 Figure 2 shows the percentage of fire-affected cells versus the variation of each index in the
237 regions of Galicia and Asturias. The point distribution fits fairly well a linear regression. Using a
238 least squares fit regression, correlation coefficients obtained range between 0.63 and 0.83 in
239 Galicia and between 0.62 and 0.72 in Asturias. Table 2 shows a summary of the adjustment
240 parameters for these indices. Note that the best correlation coefficients are obtained when
241 using the EVI from MOD13 product in both, Galicia and Asturias.

242 **Insert Figure 2.**

243 **Insert Figure 3.**

244 **Insert Table 2.**

245 For the validation, the equations previously obtained for each index were applied to the data
246 reserved for validation, and results were compared to the fire data registered during those
247 years. Table 3 presents the quantitative results of this adjustment and a statistical analysis
248 (Willmott, 1982). As noted in Table 2, the best correlation coefficients, as well as the lowest
249 estimation errors, are obtained when using the EVI provided by the MOD13 product. Based on
250 this analysis it can be concluded that EVI provided by the MOD13 product is the best indicator
251 of fire risk in Galicia and Asturias. Therefore, using this index the probability of fire occurrence
252 in a cell can be estimated with an error around 10% in Galicia and less than 20% in Asturias.
253 Best results are obtained in Galicia since the high number of fires improves the statistics.

254 **Insert Table 3.**

255 Operative systems to predict fire risk work on a graduated scale based on a previous
256 classification. As an example, in this paper we defined three risk levels from the variation of
257 EVI, although the parameter obtained pretends to be combined with other variables in a more

258 complex fire risk model. A proper classification of risk levels was proposed so that the
259 probability of fire at different levels does not overlap and that the percentage of cases in the
260 three levels were significant.

261 High risk: $\Delta EVI < -0.03$

262 Medium risk: $-0.03 < \Delta EVI < 0.03$

263 Low risk: $\Delta EVI > 0.03$

264 Applying this classification of risk levels approximately 50% of the cells are labeled as medium
265 risk, about 20% as high risk and 30% as low risk. Furthermore the highest fire frequency is
266 observed in cells labeled with high risk, obtaining a fire probability of 39%, while in lowest
267 corresponds to low risk labeled cells with 26% fire probability (figure 4 and table 4).

268 **Insert Figure 4.**

269 **Insert Table 4.**

270 This classification allows obtaining fire risk maps each 16 days. Figure 5 is an example of fire
271 risk maps for each region. Note that most fires occur in high risk cells, while in low risk cells
272 there are very few fires.

273 **Insert Figure 5.**

274

275 **CONCLUSIONS**

276 Three vegetation indices are shown suited to estimate probability of fire occurrence in Galicia
277 and Asturias: EVI, SAVI and GEMI. Eight different indices were tested as indicators of fire risk,
278 however, only those three showed a positive correlation between their variation and the
279 frequency of fires. The EVI provided the best results in the validation, with relative errors
280 around 10% in Galicia and less than 20% in Asturias. Three levels of fire risk (low, medium,
281 high) were defined from this index that will allow us to foresee the higher or lower probability
282 of fire ignition in each singular cell that divide the regions of Galicia and Asturias with fire
283 prevention and suppression purposes.

284

285 **Acknowledgements**

286 This work has been financed by the Science and Innovation Spanish Ministry (Projects
287 CGL2007-64666/CLI, CGL2010-17577/CLI and *Juan de la Cierva* research contract of J. M.
288 Sánchez), and *Generalitat Valenciana* (Project PROMETEO/2009/086). We are thankful to
289 University of Santiago de Compostela and University of Vigo for providing the fire data and
290 collaborating in this study.

291

292 **References**

- 293 AGUADO, I., CHUVIECO, E., BORÉN, R., NIETO, H., (2007). Estimation of dead fuel moisture
294 content from meteorological data in Mediterranean areas. Applications in fire danger
295 assessment. *International Journal of Wildland Fire*, 16, 390-397.
- 296 ALONSO-BETANZOS, A., FONTENLA-ROMERO, O., GUIJARRO-BERDIÑAS, B., HERNÁNDEZ-
297 PEREIRA, E., PAZ ANDRADE, I., JIMÉNEZ, E., LEGIDO, J.L., CARBALLAS, T., (2003). An intelligent
298 system for forest fire risk prediction and fire fighting management in Galicia. *Expert Systems*
299 *with Applications*, 25, 545-554.
- 300 CASTRO, F.X., TUDELA, A., SEBASTIÀ, M.T., (2003). Modeling moisture content in shrubs to
301 predict fire risk in Catalonia (Spain). *Agricultural and Forest Meteorology*, 116, 49-59.
- 302 CECCATO, P., GOBRON, N., FLASSE, S., PINTY, B., TARANTOLA, S., (2002). Designing a spectral
303 index to estimate vegetation water content from remote sensing data: Part 1. Theoretical
304 approach. *Remote Sensing of Environment*, 82, 188-197.
- 305 CHENG, Y., ZARCO-TEJADA, P.J., RIAÑO, D., RUEDA, C.A., USTIN, S. L. (2006). Estimating
306 vegetation water content with hyperspectral data for different Canopy scenarios:
307 Relationships between AVIRIS and MODIS indexes. *Remote Sensing of Environment*, 105, 354-
308 366.
- 309 CHUVIECO, E., COCERO, D., RIAÑO, D., MARTÍN, P., MARTÍNEZ-VEGA, J., DE LA RIVA, J., PÉREZ,
310 F. (2004). Combining NDVI and surface temperatura for the estimation of live fuel moisture
311 content in forest fire danger rating. *Remote Sensing of Environment*, 92, 322-331.

12

312 DENNISON, P.E., ROBERTS, D.A., PETERSON, S.H., RECHEL, J. (2005). Use of Normalized
313 Difference Water Index for monitoring live fuel moisture. *International Journal of Remote*
314 *Sensing*, 26, 1035-1042.

315 GAO, B.C. (1996). NDWI — a normalized difference water index for remote sensing of
316 vegetation liquid water from space. *Remote Sensing of Environment*, 58, 257-266.

317 GITELSON, A.A., KAUFMAN, Y.J., STARK, R., RUNDQUIST, D. (2002). Novel algorithms for
318 remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80, 76-87.

319 HUETE A.R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*,
320 25, 295-309.

321 HUETE, A., DIDAN, K., MIURA, T., RODRÍGUEZ, E.P., GAO, X., & FERREIRA, L.G. (2002). Overview
322 of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote*
323 *Sensing of Environment*, 83, 195-213.

324 HUNT, E.R., & ROCK, B.N. (1989). Detection of changes in leaf water-content using near-
325 infrared and middle-infrared reflectances. *Remote Sensing of Environment*, 30, 43-54.

326 LOZANO, F.J., SUÁREZ-SEOANE, S. y DE LUIS, E. (2007). Assessment of several spectral indices
327 derived from multi-temporal Landsat data for fire occurrence probability modelling. *Remote*
328 *Sensing of Environment*, 107, 533-544.

329 LOZANO, F.J., SUÁREZ-SEOANE, S., KELLY, M., LUIS, E. (2008). A multi-scale approach for
330 modelling fire occurrence probability using satellite data and classification trees: A case study
331 in a mountainous Mediterranean region. *Remote Sensing of Environment*, 112, 708-719.

332 MAKI, M., ISHIAHRA, M. y TAMURA, M. (2004). Estimation of leaf water status to monitor the
333 risk of forest fires by using remotely sensed data. *Remote Sensing of Environment*, 90, 441-450.

334 MARTÍN, A., DÍAZ-RAVIÑA, M., CARBALLAS, T., (2009). Evolution of composition and content of
335 soil carbohydrates following forest wildfires. *Biology and fertility of soils*, 45, 5, 511-520.

336 MASELLI, F., ROMANELLI, S., BOTTAI, L., y ZIZPOLI, G. (2003). Use of NOAA-AVHRR NDVI images
337 for the estimation of dynamic fire risk in Mediterranean areas. *Remote Sensing of*
338 *Environment*, 86, 187-197.

339 PALACIOS-ORUETA, A., CHUVIECO, E., PARRA, A., CARMONA-MORENO, C., 2005. Biomasa
340 burning emissions: a review of models using remote-sensing data. *Environmental monitoring*
341 *and assessment*, 104, 189-209.

342 PINTY, B. y VERSTRAETE, M.M. (1992). GEMI: a non-linear index to monitor global vegetation
343 from satellites. *Vegetatio*, 101, 15-20.

344 ROUSE, J.W., HASS, R.H., SCHELL, J.A., & DEERING, D.W. (1974). Monitoring vegetation systems
345 in the Great Plains with ERTS. *Proceedings, third Earth Resources Technology Satellite-1*
346 *Symposium, Greenbelt, NASA SP-351* (pp. 309-317).

347 SEBASTIÁN-LÓPEZ, A., SAN-MIGUEL-AYANZ, J., BURGAN, R.E., (2002). Integration of satellite
348 sensor data, fuel type maps and meteorological observations for evaluation of forest fire risk
349 at the pan-European scale. *International Journal of Remote Sensing*, 23, 2713-2719.

350 SHNEIDER, P., ROBERTS, D.A., KYRIAKIDIS, P.C. (2008). A VARI-based relative greenness from
351 MODIS data for computing the Fire Potential Index. *Remote Sensing of Environment*, 113,
352 1151-1167.

353 STOW, D., NIPHADKAR, M., KAISER, J. (2005). MODIS-derived visible atmospherically resistant
354 index for monitoring chaparral moisture content. *International Journal of Remote Sensing*, 26,
355 3867-3873.

356 VERBESSELT, J., JÖNSSON, P., LHERMITTE, S., VAN AARDT, J., COPPEN, P., (2006). Evaluating
357 satellite and climate data-derived indices as fire risk indicators in savanna ecosystems. *IEEE*
358 *Transactions on Geoscience and Remote Sensing*, 44, 1622-1632.

359 WILLMOTT, C.J. (1982). Some comments on the evaluation of model performance. *Bull. Am.*
360 *Meteorol. Soc.*, 63, 1309-1313.

361 YEBRA, M., CHUVIECO, E., RIAÑO, D. (2008). Estimation of live fuel moisture content from
362 MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*, 148, 523-536.
363
364
365
366
367
368
369
370
371
372
373
374

375

Table 1. Spectral indices for the estimation of the vegetation status using MODIS.

Normalized Difference Vegetation Index	$NDVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1}$	Rouse et al., 1974
Soil Adjusted Vegetation Index	$SAVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1 + L} (1 + L)$, $L=0,25$	Huete, 1988
Normalized Difference Infrared Index	$NDII = \frac{\rho_2 - \rho_6}{\rho_2 + \rho_6}$	Hunt and Rock, 1989
Global Environmental Monitoring Index	$GEMI = \frac{\rho_2 - 0,125}{1 - \rho_1}$ $eta = \frac{2(\rho_2^2 - \rho_1^2) + 1,5\rho_2 + 0,5\rho_1}{\rho_2 + \rho_1 + 0,5}$	Pinty and Verstraete, 1992
Normalized Difference Water Index	$NDWI = \frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$	Gao, 1996
Visible Atmospheric Resistant Index	$VARI = \frac{\rho_4 - \rho_1}{\rho_4 + \rho_1 - \rho_3}$	Gitelson et al., 2002
Enhanced Vegetation Index	$EVI = 2,5 \frac{\rho_2 - \rho_1}{\rho_2 + 6\rho_1 - 7,5\rho_3 + 1}$	Huete et al., 2002
Global Vegetation Moisture Index	$GVMi = \frac{(\rho_2 + 0,1) - (\rho_6 + 0,02)}{(\rho_2 + 0,1) + (\rho_6 + 0,02)}$	Ceccato et al., 20

376

377

378 Table 2. Results of the linear regression between the frequency of fire affected cells and the
 379 index variations for three different indices in Galicia and Asturias (a: slope, b: interception, r^2 :
 380 regression coefficient, σ : standard deviation, n: number of cases considered).

Region	Index	a	b	r^2	σ	n
GALICIA	GEMI	-0.92±0.09	0.308±0.007	0.81	0.03	7509
	EVI	-1.00±0.10	0.316±0.007	0.83	0.03	7509
	SAVI	-1.29±0.17	0.322±0.009	0.78	0.04	7514
	EVI (MOD13)	-1.41±0.13	0.323±0.009	0.84	0.04	7331
ASTURIAS	GEMI	-0.97±0.16	0.180±0.010	0.66	0.04	2930
	EVI	-0.95±0.14	0.178±0.009	0.70	0.03	2960
	SAVI	-1.1±0.2	0.184±0,012	0.60	0.05	2947
	EVI (MOD13)	-0.80±0.14	0.185±0.009	0.62	0.04	2778

381

382

383

384 Table 3. Statistic analysis of the linear fit between the observed and estimated fire
 385 probabilities using the validation data for three different indices in Galicia and Asturias.

Región	Índice	a	b	R ²	Bias ¹	RMSE ²	RMSES ³	RMSEU ⁴	MAD ⁵	MADP ⁶
GALICIA	GEMI	0.57±0.09	0.13±0.03	0.67	-0.00017	0.05	0.04	0.04	0.04	12%
	EVI	0.62±0.08	0.11±0.03	0.73	-0.007	0.05	0.03	0.03	0.04	11%
	SAVI	0.59±0.09	0.13±0.03	0.71	0.006	0.05	0.04	0.04	0.04	13%
	EVI (MOD13)	0.97±0.10	0.01±0.03	0.81	0.003	0.04	0.003	0.04	0.03	11%
ASTURIAS	GEMI	0.53±0.12	0.08±0.02	0.53	-0.0016	0.05	0.03	0.04	0.03	19%
	EVI	0.65±0.14	0.06±0.03	0.54	0.004	0.04	0.02	0.04	0.03	19%
	SAVI	0.47±0.15	0.09±0.03	0.41	0.003	0.05	0.04	0.04	0.03	21%
	EVI (MOD13)	0.71±0.12	0.06±0.02	0.65	0.005	0.04	0.019	0.03	0.03	15%

386 ¹ Bias: $Bias = N^{-1} \sum_{i=1}^N (P_i - O_i)$

387 ² Root Mean Square Difference: $RMSE = \left[N^{-1} \sum_{i=1}^N (P_i - O_i)^2 \right]^{0.5}$

388 ³ Systematic Root Mean Square Difference: $RMSES = \left[N^{-1} \sum_{i=1}^N (P_i - O_i)^2 \right]^{0.5}$

389 ⁴ Non-systematic Root Mean Square Difference: $RMSEU = \left[N^{-1} \sum_{i=1}^N (P_i - P_i')^2 \right]^{0.5}$

390 ⁵ Mean Absolute Difference: $MAD = N^{-1} \sum_{i=1}^N |P_i - O_i|$

391 ⁶ Mean Absolute Difference in Percentage: $MAD = 100 MAD / \langle O_i \rangle$


392 where P_i y O_i are predicted and observed values, respectively, and $P_i = aO_i + b$.

393


394 Table 4. Fire probability for each risk level.

	EVI (MOD13) Galicia	EVI (MOD13) Asturias
High	39±5	22±4
Medium	31.3±0.9	18±2
Low	26±5	14±3

395



396
397 Figure 1. 16-day cumulative fire events in Galicia and Asturias averaged over 2001-2006.




398

399

(a)

(b)




400

401

(c)

(d)

402 Figure 2. Linear adjustment between the percentage of fire-affected cells in Galicia and
403 Asturias and the indices variation in the previous two weeks, for the 50% of the total temporal
404 series available and for the indices: a) EVI(MOD13), b) EVI(MOD09), c) GEMI, d) SAVI.




405

406

407

408

(a) (b)
 Figure 3. Fire probability versus the variations of the indices NDWI, GVMi, NDVI, NDII and VARI for: a) Galicia, b) Asturias.



409

410

411

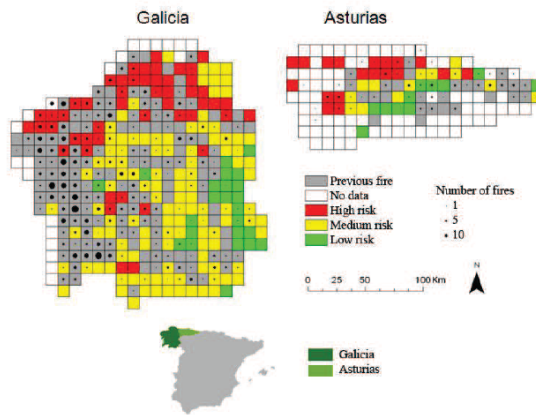
412

413

414

415

(a) (b)
 Figure 4. Fire probability values for the different risk levels assigned using the EVI(MOD13) for: a) Galicia, b) Asturias.



416

417 Figure 5. Fire risk maps for Galicia (2-17 February 2006) and Asturias (7-22 April 2001). Black

418

points represent the number of fires registered in each cell.

419

420

Anexo E

Artículo “*Fire danger estimation from MODIS Enhanced Vegetation Index data. Application to Galicia region (northwest Spain).*”

El presente estudio fue aceptado por la revista International Journal of Wildland Fire el mes de septiembre de 2010. Esta revista tiene un factor de impacto de **1,9** y ocupa la posición 6 de las 46 revistas de la categoría de “Forestry” indexadas en el ISI-Journal of Citation Reports Science Edition 2009.

1 Fire danger estimation from MODIS Enhanced
2 Vegetation Index data. Application to Galicia region
3 (northwest Spain).

4 *Suggested running head: Fire danger estimation in Galicia, Spain, from MODIS data*

5
6 M. M. Bisquert^a, J. M. Sánchez^{b*}, V. Caselles^a

7
8 *Juanmanuel.sanchez@uclm.es

9
10 ^a Earth Physics and Thermodynamics Department, University of Valencia, 46100, Burjassot, Spain

11 ^b Applied Physics Department, University of Castilla-La Mancha, 02071, Albacete, Spain

12
13
14 **ABSTRACT**

15
16 Galicia, in northwest Spain, is a region specially affected by devastating impacts of
17 forest fires. Development of a fire danger prediction model adapted to the necessities of
18 this particular region is required. In this paper, we focus on the changes in the
19 vegetation condition as an indicator of fire danger. The potential of the Enhanced
20 Vegetation Index (EVI) together with the period-of-year to monitor vegetation changes
21 in Galicia is shown. The Moderate Resolution Imaging Spectroradiometer (MODIS),
22 onboard Terra satellite, was chosen for this study. A six-year dataset of EVI images,
23 from the product MOD13Q1 (one image each 16 days), together with fire data in a
24 10×10 km grid basis, were used. Logistic regression was used to assess the relation
25 between the percentage of fire activity and EVI variations together with period-of-year.
26 Results showed the capacity of the model obtained to discriminate different levels of
27 fire occurrence danger, with an estimation error around 5%. This remote sensing
28 technique may then contribute to increase the efficiency of the fire prevention systems
29 currently used.

30
31 **Key words:** EVI, MODIS, fire danger, Galicia.

32

33 **Introduction**

34

35 Forest fires are a major driver of forest disturbance, affecting the landscape, the natural
36 cycle of the vegetation, and the structure and function of the ecosystems (Koutsias and
37 Karteris 2000; Lozano et al. 2008). Huge fires may affect even climate change since
38 they are an additional source of green-house gases, hydrocarbons and aerosols, released
39 into the atmosphere during the biomass combustion process (González-Alonso et al.
40 1997). Also, changes in albedo and surface temperature after a forest fire may have a
41 significant impact on the regional and global climate through the modification of the
42 surface energy flux patterns (Sánchez et al. 2009).

43 Fire danger prediction and fire damage estimation are highly valuable tools. However,
44 in situ data collection is limited by economical and human resources. Remote sensing
45 offers viable alternatives to in situ measurements. Sensors onboard satellites capture the
46 surface reflectance and emittance in different spectral ranges and with variable
47 temporal and spatial resolution. Information on a wide range of surface parameters can
48 be extracted using these radiance measures as a basis.

49 Satellite remote sensing has been used in fire management for the last 20 years with
50 different aims: identification and monitoring of burned areas, detection of on-going
51 burning, and fire danger estimation (Maselli et al. 2003; González-Alonso et al. 1997;
52 Lozano et al. 2007 and 2008). Remote sensing is then useful in forest fire prediction,
53 monitoring and suppression phases, and planning the rehabilitation of burned areas.

54 Topography, meteorological variables, and vegetation condition are the main natural
55 inputs included in fire danger models (Castro et al. 2003; Alonso-Betanzos et al. 2003;
56 Aguado et al. 2007). In this paper we focus on the last topic. Our main objective is to

57 develop relationships between vegetation condition and the probability of fire
58 occurrence. Note that relation between fire occurrence and environmental parameters
59 might be complex, with human factors playing a key role. Despite this fact, fire danger
60 shows a significant dependence with the vegetation water content (Yebara et al., 2008;
61 Maki et al., 2004; Chuvieco et al., 2002). Live vegetation water content can be
62 expressed via different terms: the Fuel Moisture Content (FMC), the Equivalent Water
63 Thickness (EWT) or the Relative Water Content (RWC) (Maki et al. 2004). Fuel
64 moisture content (FMC) is defined as the ratio between the quantity of water in
65 vegetation and either the fresh or dry weight of vegetation (Maki et al. 2004). The
66 equivalent water thickness (EWT) (Danson et al., 1992) is defined as the ratio between
67 the quantity of water (the difference between fresh leaf weight and dry leaf weight) and
68 the leaf area. And the relative water content (RWC) (Inoue et al., 1993) is defined as the
69 ratio between the quantity of water at the time of measurement and the quantity of water
70 at full turgor. Direct application of these magnitudes to predict fire danger is quite
71 limited when monitoring wide areas since they require detailed surface sampling.
72 Remote sensing becomes an essential tool at this point, allowing to monitor spatial and
73 temporal variations of water content over large areas. Water shows specific absorption
74 properties in particular regions of the electromagnetic spectrum. Variations in this
75 spectral absorption of the vegetation are produced by changes in water quantity, as well
76 as in its structure and photosynthetic pigments (Yu et al. 2000; Ceccato et al. 2001).
77 Recent studies have shown the relation between the live vegetation water content and
78 the spectral reflectances, and results have been compared with direct gravimetric
79 measures (Maki et al. 2004; Gillon et al. 2004; Dennison et al. 2005; Stow et al. 2005;
80 Cheng et al. 2006). These studies focused on the shortwave infrared (SWIR), near
81 infrared (NIR), visible, and thermal infrared (TIR) domains of the electromagnetic

82 spectrum. Different indices have been proposed from reflectance values. Depending on
83 the spectral bands used we have: the Normalized Difference Vegetation Index (NDVI)
84 (Rouse et al. 1974), the Normalized Difference Water Index (NDWI) (Gao 1996), the
85 Normalized Difference Infrared Index (NDII) (Hunt and Rock 1989), the Leaf Water
86 Content Index (LWCI) (Hunt et al. 1987), the Vegetation Dryness Index (VDI) (Maki et
87 al. 2004), the Visible Atmospherically Resistant Index (VARI) (Stow et al. 2005), the
88 Enhanced Vegetation Index (EVI) (Huete et al. 2002), etc. Some of these indices, such
89 as NDVI, EVI or VARI, do not use water absorption bands; however they are very
90 sensitive to Leaf Area Index (LAI) and chlorophyll content variations linked to the
91 drying process in many species (Yebra et al. 2008). For each vegetation type the FMC
92 behaviour is better represented by a particular index. Maki et al. (2004) tested the
93 relationship between NDWI and EWT in a coniferous site. Using data from a forest in
94 Los Angeles, Dennison et al. (2005) observed that measures of water absorption, given
95 by NDWI, might be more appropriate to monitor FMC than the measure of chlorophyll
96 absorption given by NDVI. Stow et al. (2005) showed more robustness and correlation
97 of the FMC with the VARI, in a shrub area in San Diego, despite the fact that VARI is
98 calculated using visible reflectance values. Results obtained by Verbesselt et al. (2006)
99 in an African savanna area yielded NDWI as the highest capacity index to predict fire
100 danger in this ecosystem. Cheng et al. (2006) compared four different indices, showing
101 the best results when using EVI in cropland and semi-arid shrubland areas, and NDWI
102 in coniferous forest. Relation between land surface temperature (LST) and vegetation
103 water content has been also studied (Moran et al. 1994). Combination of LST and
104 NDVI is more correlated to vegetation moisture content than any of them separately
105 (Alonso et al. 1996; Chuvieco et al. 2004). Thus, it has not been possible to identify a
106 single index as the most efficient for fire danger prediction since it strongly depends on

107 the site, vegetation type, and environmental conditions. Also, works showing the direct
108 relation between indices and fire data are scarce. Some examples are the analysis of
109 NDVI data, obtained by the Advanced Very High Resolution Radiometer (AVHRR)
110 onboard NOAA satellite, to monitor fire danger (González-Alonso et al. 1997; Maselli
111 et al. 2003). More recently, a few works use the Moderate Resolution Imaging
112 Spectroradiometer (MODIS) onboard Terra and Aqua platforms. Schneider et al. (2008)
113 selected VARI to estimate Relative Greenness (RG) from a series of MODIS images,
114 and to test fire data in a California Southern area using logistic regression. This same
115 technique was used by Lozano et al. (2007) to assess the performance of several spectral
116 indices derived from Landsat data when modelling fire occurrence probability in a
117 Natural Park in north-western Spain. From the same dataset Lozano et al. (2008)
118 explored the relationships between fire occurrence and several families of
119 environmental factors at different spatial observation scales by means of regression tree
120 models.

121 The objective of this work is to explore the potential of the EVI to predict fire danger in
122 the Galicia region by detecting changes in the vegetation stage prior to the fire event,
123 this variable is combined with the period-of-year studied. The model obtained would be
124 a valuable tool to determine the fire danger, and assign danger labels, from the
125 operational information provided by remote sensing. A description of the study site as
126 well as the information and satellite images used are shown in Section 2. The applied
127 methodology is presented in Section 3. Results obtained are shown in Section 4. Main
128 conclusions are finally summarized in Section 5.

129

130

131 **Study site and data sources**

132

133 Galicia is located at the northwest of the Iberian Peninsula, occupying an area of 29575
134 km² (Fig. 1). The climate of Galicia is temperate, transitioning between oceanic and
135 Mediterranean, with mild winters and cool summers. Galicia receives considerable
136 amount of rainfall (in average ~1200 mm annually, Ministerio de Medio Ambiente y
137 Medio Rural y Marino 2008) transferred to the west oceanfront of the Iberian Peninsula
138 from the Atlantic ocean by the dominant winds. About 67% of the land surface in
139 Galicia is occupied by forests (mainly coniferous, *Pinus Pinaster Ait.*, and eucalyptus),
140 (Xunta de Galicia, 2001). Despite the high levels of vegetation moisture content,
141 Galicia is the Spanish region with the highest concentration of forest fires (Ministerio de
142 Medio Ambiente, 2006). Thus, modelling the fire danger from vegetation index
143 information is specially challenging under these conditions.

144 Historic records of forest fire data in Galicia are provided using a grid as a basis
145 dividing Galicia in 360 10-km side squares (UTM 29). This grid is also used for
146 management of the fire forecasting and suppression tasks. Unfortunately, exact
147 coordinates of these fire events were not available. Information on vegetation stage was
148 then adapted to this spatial resolution, 10×10 km, using the same grid as a basis. Two-
149 week composites were selected to monitor the vegetation condition for two reasons:
150 dominant vegetation in this region is not expected to change significantly within this
151 period, and higher temporal resolution would increase the cloud-affected surface.

152 MODIS is an orbital 36-band sensor with a spatial resolution ranging from 250 m to 1
153 km, a swath of more than 2000 km, and a revisit time of 24 hours (at the latitude of the
154 study site). MODIS scenes are processed and different products are available, in
155 particular, the product MOD13Q1 Vegetation Indices 16-Day L3 Global 250m (Huete
156 et al. 1999) was used for this study. This is a composite of 16 day images containing

157 processed NDVI and EVI data at 250m spatial resolution (Fig. 1), fitting the spatial and
158 temporal requirements for this study. MOD13Q1 images were provided by the NASA
159 Land Processes Distributed Active Archive Center (LPDAAC), covering a 6-years
160 period, from 2001 to 2006. Moreover, by using 16-day composites, problems related to
161 clouds presence (frequent in this region) can be mitigated since only cloud-free values
162 (based on the quality band included in each MODIS product) are assigned to each
163 particular pixel. We adopted MODIS land cover classification product MOD12Q1
164 (Strahler et al., 1999), and particularly the Land Cover Type 3 classification, to divide
165 the landscape into 4 broad categories: agricultural areas, forest, shrubland, and non-
166 vegetated areas (Table 1).

167 Fig. 2 shows a histogram of the 6-year period averages of fire events in Galicia. Two
168 separated peaks can be discerned, the principal peak in the summer time and a
169 secondary peak centred in March. Note that February-October is the period that
170 concentrates the majority of fire events (94% of annual amount). The analysis was
171 constrained to this period to avoid presence of a minority of events that might
172 contaminate the overall statistics of the model performance.

173

174

175 **Methodology**

176

177 Three different steps can be considered: (i) pre-processing of the MODIS images, (ii)
178 selection of EVI as the most appropriate index for the study, (iii) obtaining algorithms
179 to estimate fire occurrence probability from the vegetation index variations and the
180 period-of-year in a particular area.

181

182 **Pre-processing of the MODIS images**

183

184 Images corresponding to the recently revised Collection 5 of the MOD13Q1 product
185 were used for this study. First, water bodies and city areas were masked (using
186 CORINE Land Cover information) to exclude non-vegetated pixels from the analysis.
187 Although cloud effect is minimized when using 16-day composite images, there may
188 still remain pixels with no valid information in the whole 16-day period. Besides, some
189 pixels may contain wrong values due to different reasons. Thus, a filtering process was
190 applied based on the data quality information included as an additional band in the
191 MOD13Q1 product. Only pixels containing acceptable information were finally
192 considered (*VI produced low quality and upper, no clouds nor snow/ice nor shadows,*
193 [https://lpdaac.usgs.gov/lpdaac/products/modis_products_table/vegetation_indices/16_da](https://lpdaac.usgs.gov/lpdaac/products/modis_products_table/vegetation_indices/16_day_13_global_250m/v5/terra)
194 [y_13_global_250m/v5/terra](https://lpdaac.usgs.gov/lpdaac/products/modis_products_table/vegetation_indices/16_day_13_global_250m/v5/terra)). In order to minimize the gaps in the filtered images, a
195 filling process was applied consisting on a 5x5 matrix assigning each pixel without
196 information the average value of the surrounding 5x5 pixels. In order to validate the
197 filling process, this was also applied to those pixels with known information. It was
198 observed that in 90% of the cases the difference between the scheduled EVI value and
199 the original one was less than 0.1. Since the final spatial resolution was 10x10 km, these
200 differences were accepted not relevant. Average values of the vegetation indices for
201 each 10x10 km cell were calculated (Fig.3) when the cell was occupied at least by 10%
202 of land and when more than 80% of the land pixels within the cell contained valid
203 information. As for the MOD12Q1 images, the different land uses were grouped in the
204 four classes aforementioned, and each 10x10 km cell was assigned the dominant land
205 use, i.e. the category with the highest occupancy percentage. Fig. 4 displays a map
206 showing the dominant land use in each cell, corresponding to 2003. This map was

207 adopted for the 6-year period of this study. Galicia is basically divided in two vegetation
208 types: forest (tree) areas and shrubland areas.

209

210 **Selection of EVI as the most appropriate vegetation index**

211

212 NDVI and EVI values are obtained from reflectance information in MODIS bands 1
213 (645 nm), 2 (858.8 nm), and 3 (469 nm). Selection of EVI was based on the analysis of
214 the evolution of both indices, NDVI and EVI, throughout the year. Fig. 5 shows an
215 example of the evolution of the average values of NDVI and EVI for the whole region,
216 and the year 2003. Seasonal variation is clearly larger for EVI. Average of the
217 differences between reaching maximum and minimum values within each particular cell
218 results 0.14 ± 0.05 and 0.19 ± 0.05 for NDVI and EVI, respectively. Also, NDVI saturates
219 around a value of 0.75 for a great part of the year, showing marginal seasonal variations
220 and thus making it difficult to search for empirical algorithms between this parameter
221 and fire probability. These findings are in agreement with other studies showing the
222 saturation of NDVI under high density vegetation conditions (Holben et al. 1980;
223 Sellers 1985). Thus, we focus our analysis on the EVI variations as the indicator of
224 change in the vegetation condition more strongly related to the fire danger of a specific
225 area.

226

227 **Relation between fire frequency and EVI variations**

228

229 Algorithms using vegetation indices as one of the inputs to predict fire danger are
230 usually focused on the absolute value of the index. However, under conditions such as
231 those in Galicia, showing high values of vegetation indices all the year long, no

232 significant relation can be established between the fire occurrence probability and the
 233 absolute EVI value.

234 Changes in EVI are expected to be more correlated to fire frequency than the EVI value
 235 itself. For this reason, EVI differences (ΔEVI) between two consecutive 16-day images
 236 were computed for each cell. Figure 6 shows a plot of ΔEVI values averaged over the 6-
 237 year period versus week-in-year. The large error bars are indicative of the high
 238 variability of ΔEVI for different years. This plot is evidence that information in ΔEVI is
 239 not simply due to the week-in-year. Moreover, week-in-year itself cannot account for
 240 the spatial variability of ΔEVI observed for the different years. However week-in-year
 241 could be used as a proxy for annual cyclical patterns of fire occurrence (Preisler et al.
 242 2008) and so it could help to predict some fires not predicted by the ΔEVI . In the
 243 present study 16-day periods have been used, so the number of the period-of-year
 244 (ranging from 1-16, period 1 corresponding to 2-17 February) was included in the
 245 model as a categorical variable for predicting fire occurrence.

246 Note that a decrease in EVI may be also consequence of a previous fire event and not
 247 only due to a natural change in the water content of the vegetation. Thus, a pre-filtering
 248 process was required to exclude from the analysis those cells affected by a previous fire
 249 and ensure that EVI variations were produced by natural changes in the vegetation
 250 water content, and not by a previous fire. Binary logistic regression was used to
 251 evaluate the relationship between ΔEVI , period-of-year and fire events. The algorithm
 252 obtained by logistic regression calculates the conditional probability, P_{fire} , of a fire
 253 occurring for a given ΔEVI and a period-of-year, according to the expression:

$$254 \quad P_{\text{fire}} = \frac{1}{1 + e^{-\alpha - \beta_{\Delta\text{EVI}}\Delta\text{EVI} - \beta_{\text{period}}}} \quad (1)$$

255 The present analysis was made by using the statistical software PASW Statistics 17.
256 The skill of each coefficient can be analyzed by the Wald test, which assesses the null
257 hypothesis that a particular coefficient is zero (Martínez et al. 2009), if the p-value is
258 less than 0.05 this means that the analysed variable is statistically significant. The value
259 of each coefficient β_i should be also analyzed. If this is not much different from zero the
260 results of the equation will not change significantly by not adding that variable, so it
261 could be excluded (Preisler et al. 2009).

262 The goodness of fit can be assessed by reliability tests such as the Hosmer-Lemeshow
263 test (Hosmer and Lemeshow 1989). This test consists on analyzing the observed values
264 versus the estimated probabilities in 10 equally divided intervals (Preisler et al. 2009), a
265 good adjustment should have a p-value greater than 0.05 in this case.

266 A c-index is also used to evaluate the discrimination power of the logistic model when
267 referring to a dichotomous variable. A c-index value lower than 0.5 indicates random
268 predictions, whereas a value higher than 0.5 is an evidence of prediction capability.

269 As shown in the introduction, relationships between vegetation indices and vegetation
270 water content may depend on the vegetation type. Efficiency of an index to predict fire
271 events may also depend on the particular area. For these reasons we checked the effect
272 of including a categorical variable representing the two dominant land uses in Galicia
273 (Fig. 4).

274

275 **Results and discussion**

276

277 After the filtering and filling processes, a set of 9876 data was available for the present
278 analysis. Two subsets were defined within the database using a random selection, 50%

279 of the data was used for algorithm development and the other 50% was used for
280 independent validation.

281 Firstly the three variables ΔEVI , period-of-year, and land use were included in the
282 adjustment. Significance value of 0.488 was obtained for the land use, which means that
283 this variable does not make any changes in the results when it is included. Thus, land
284 use was not considered in the adjustment. The reader should take into account that these
285 results might be affected by the way the 10×10 km cells were assigned the distinct
286 vegetation categories; for instances, a particular cell with a 45% shrub landscape and
287 55% forest landscape, and a very similar one but now with a 55% shrubland and 45%
288 forest are classified within distinct categories. A more exhaustive analysis could have
289 been done at this point provided fire information at a higher spatial resolution had been
290 available for this study.

291 Table 2 shows the results for the variables α , $\beta_{\Delta\text{EVI}}$ and β_{period} in equation (1) for the
292 training dataset. The parameter β_{period} is different for each period, since the period-of-
293 year is a categorical variable. The corresponding concordance levels obtained with the
294 logistic regressions for the training and the validation set are included in Table 3.
295 Overall concordance is over 58%. Observed fires are predicted in more than 56% of the
296 occasions. For the analysis of goodness-of-fit a Hosmer-Lemeshow test was carried out.
297 A p-value greater than 0.05 ($P=0.408$) was obtained, which is an evidence of good
298 adjustment. The Hosmer-Lemeshow test is shown in table 4, and the observed and
299 estimated probability values obtained from this data are represented in figure 7.

300 Beyond the potential of ΔEVI and period-of-year to predict a dichotomous dependent
301 variable (fire/no fire), equation 1, with coefficients in Table 2, provides an estimate of
302 the continuous probability of fire occurrence within a particular cell, for the two-week
303 period following the satellite image date. We tested the capability of this model to

304 discriminate fire probability using the data in table 4. Results obtained by applying the
305 logistic regression model were compared to the fire data registered (Fig. 7). Results of
306 this linear regression show a slope of 0.98 ± 0.06 and an interception of 0.01 ± 0.02 with a
307 regression coefficient of 0.97. A negligible bias was obtained, as well as a root mean
308 square error and an average relative error of 0.018 and 5%, respectively.

309 Existing systems to predict fire danger, usually work on a graduate scale based on a
310 previous classification. A classification based on only three categories was then
311 established. The optimized limits are:

- 312 - High danger: $P_{\text{fire}} < 0.27$
- 313 - Medium danger: $0.27 < P_{\text{fire}} < 0.35$
- 314 - Low danger: $P_{\text{fire}} > 0.53$

315 The definition of these categories was based on two criteria: the probabilities in the
316 three categories must be as discerned as possible, and the number of cases in each level
317 must be comparable. Grouping the data in these three categories, the average fire-
318 affected cell percentages resulted in 0.393 ± 0.012 , 0.316 ± 0.007 , and 0.216 ± 0.011 for
319 high, medium and low danger, respectively (Fig. 8a).

320 Besides the potential to predict fire danger in a particular cell, it is interesting to analyze
321 the effect on the fire density, i.e., the number of events per cell. Fig. 8b shows this
322 average number of fires per cell versus the corresponding occurrence probability. A
323 linear dependence is observed, evidence that high and low danger can be also linked to
324 higher and lower fire density, respectively.

325 The present work will be further completed with the application and validation of the
326 model in other regions as well as the comparison with other vegetation indices. Also,
327 ΔEVI will be combined with ancillary variables such as land surface temperature or fire
328 history, to improve the overall concordance of the logistic regression models.

329

330

331 **Conclusions**

332

333 The performance of the selected Enhanced Vegetation Index together with period-of-
334 year for fire danger assessment in Galicia was evaluated. Spectral indices are indicators
335 of particular and site-specific conditions and they can be a valuable extra source of
336 information for the fire prediction systems. We focused on the relationship between the
337 EVI variations and fire activity data. The aim was to evaluate the potential of MODIS
338 data towards an operational implementation of vegetation index information for fire
339 danger assessment.

340 In this work we used MODIS images (MOD13Q1 product) from 2001 to 2006, with a
341 rescaled spatial resolution of 10×10 km. Binary logistic regression was used to obtain
342 an algorithm in which EVI variations between two consecutive scenes and period-of-
343 year are the independent variables, and the predicted probability of fire occurrence is the
344 dependent variable. The prediction agreement found between the binary outputs of the
345 logistic model (high or low risk) was sufficient to consider the predictive power of this
346 model in Galicia (c-index over 50%). Good agreement was observed in terms of
347 continuous fire probability. It was proved that making a distinction between different
348 land uses was not necessary. An average root mean square error of 0.018 with a
349 negligible bias, and a relative error around 5%, were obtained when comparing
350 algorithm results with observed fire data. A three-level scale of fire danger (high,
351 medium and low) was defined, as a function of the probabilities obtained from the
352 model. This classification allows us to assign a higher or lower probability of fire
353 occurrence, as well as to predict a higher or lower fire density, to each particular cell in

354 which Galicia is divided for the management of the fires prediction and suppression
355 tasks. Further research is needed to investigate the performance of more complete and
356 complex fire danger indices when introducing satellite EVI information as an additional
357 input.

358

359 **Acknowledgements**

360

361 This work has been financed by the Science and Innovation Spanish Ministry (Projects
362 CGL2007-64666/CLI, CGL2008-03668/CLI, and *Juan de la Cierva* research contract of
363 J. M. Sánchez), and *Generalitat Valenciana* (Project PROMETEO/2009/086). We are
364 thankful to University of Santiago de Compostela and University of Vigo for providing
365 the fire data and collaborating in this study.

366

367

368 **References**

369

370 Aguado I, Chuvieco E, Borén R, Nieto H (2007) Estimation of dead fuel moisture
371 content from meteorological data in Mediterranean areas. Applications in fire
372 danger assessment. *International Journal of Wildland Fire* **16**, 390-397.

373 Alonso-Betanzos A, Fontenla-Romero O, Guijarro-Berdiñas B, Hernández-Pereira E,
374 Paz Andrade I, Jiménez E, Legido JL, Carballas T (2003). An intelligent system
375 for forest fire risk prediction and fire fighting management in Galicia. *Expert*
376 *Systems with Applications* **25**, 545-554.

- 377 Alonso M, Camarasa A, Chuvieco E, Cocero D, Kyun I., Martín MP, Salas FJ (1996)
378 Estimating temporal dynamics of fuel moisture content of Mediterranean species
379 from NOAA-AVHRR data. *EARSEL Advances in Remote Sensing* **4**, 9-24.
- 380 Castro FX, Tudela A, Sebastià MT (2003) Modelling moisture content in shrubs to
381 predict fire risk in Catalonia (Spain). *Agricultural and Forest Meteorology* **116**,
382 49-59.
- 383 Ceccato P, Flasse S, Tarantola S, Jacquemoud S, Gregoire JM (2001) Detecting
384 vegetation leaf water content using reflectance in the optical domain. *Remote*
385 *Sensing of Environment* **77**, 22-33.
- 386 Cheng Y, Zarco-Tejada PJ, Riaño D, Rueda CA, Ustin SL (2006) Estimating vegetation
387 water content with hyperspectral data for different Canopy scenarios:
388 Relationships between AVIRIS and MODIS indexes. *Remote Sensing of*
389 *Environment* **105**, 354-366.
- 390 Chuvieco E, Riaño D, Agudao I, Cocero D (2002) Estimation of fuel moisture content
391 from multitemporal analysis of Landsat Thematic Mapper reflectance data:
392 applications in fire danger assessment. *International Journal of Remote Sensing*
393 **23(11)**, 2145-2162.
- 394 Chuvieco E, Cocero D, Riaño D, Martín P, Martínez-Vega J, De la Riva J, Pérez F
395 (2004) Combining NDVI and surface temperatura for the estimation of live fuel
396 moisture content in forest fire danger rating. *Remote Sensing of Environment* **92**,
397 322-331.
- 398 Danson FM, Steven MD, Malthus TJ, Clark JA (1992) High-spectral resolution data for
399 determining leaf water content. *International Journal of Remote Sensing* **13 (3)**,
400 461-470.

- 401 Dennison PE, Roberts DA, Peterson SH, Rechel J (2005) Use of Normalized Difference
402 Water Index for monitoring live fuel moisture. *International Journal of Remote*
403 *Sensing* **26**, 1035-1042.
- 404 Gao BC (1996) NDWI — a normalized difference water index for remote sensing of
405 vegetation liquid water from space. *Remote Sensing of Environment* **58**, 257-
406 266.
- 407 Gillon D, Dauriac F, Deshayes M, Valette JC, Moro C (2004) Estimation of foliage
408 moisture content using near infrared reflectance spectroscopy. *Agricultural and*
409 *Forest Meteorology* **124**, 51-62.
- 410 González-Alonso F, Cuevas JM, Casanova JL, Calle A, Illera, P (1997) A forest fire
411 risk assessment using NOAA AVHRR images in the Valencia area, eastern
412 Spain. *International Journal of Remote Sensing* **18 (10)**, 2201-2207.
- 413 Holben BN, Tucker CJ, Fan C-J (1980) Spectral assessment of soybean leaf area and
414 leaf biomass. *Photogrammetric Engineering and Remote Sensing* **46**, 651-656.
- 415 Hosmer DW, Lemeshow S (1989). Applied Logistic Regression. Wiley series in
416 Probability and Mathematical Statistics, John Wiley and Sons, New York.
- 417 Huete A, Didan K, Miura T, Rodriguez EP, Gao X, Ferreira LG (2002) Overview of the
418 radiometric and biophysical performance of the MODIS vegetation indices.
419 *Remote Sensing of Environment* **83**, 195-213.
- 420 Huete A, Justice C, van Leeuwen W (1999) MODIS Vegetation Index (MOD13)
421 Algorithm Theoretical Basis Document.
- 422 Hunt ER, Rock BN (1989) Detection of changes in leaf water-content using near-
423 infrared and middle-infrared reflectances. *Remote Sensing of Environment* **30**,
424 43-54.

- 425 Hunt ER, Rock BN, Nobel PS (1987) Measurement of leaf relative water content by
426 infrared reflectance. *Remote Sensing of Environment* **22**, 429-435.
- 427 Inoue Y, Morinaga S, Shibayama M (1993) Non-destructive estimation of water status
428 of intact crop leaves based on spectral reflectance measurements. *Japan Journal*
429 *of Crop Science*, **62(3)**, 462-469.
- 430 Koutsias N, Kartesis M (2000) Burned areas mapping using logistic regression
431 modelling of a single post-fire Landsat-5 Thematic Mapper image. *International*
432 *Journal of Remote Sensing* **21**, 673-687.
- 433 Lozano FJ, Suárez-Seoane S, Kelly M, Luis E (2008) A multi-scale approach for
434 modelling fire occurrence probability using satellite data and classification trees:
435 A case study in a mountainous Mediterranean region. *Remote Sensing of*
436 *Environment* **112**, 708-719.
- 437 Lozano FJ, Suárez-Seoane S, Luis E (2007) Assessment of several spectral indices
438 derived from multi-temporal Landsat data for fire occurrence probability
439 modelling. *Remote Sensing of Environment* **107**, 533-544.
- 440 Maki M, Ishihara M, Tamura M (2004) Estimation of leaf water status to monitor the
441 risk of forest fires by using remotely sensed data. *Remote Sensing of*
442 *Environment* **90**, 441-450.
- 443 Martínez J, Vega-García C, Chuvieco E (2009) Human-caused wildfire risk rating for
444 prevention planning in Spain. *Journal of Environmental Management* **90**, 1241-
445 1252.
- 446 Maselli F, Romanelli S, Bottai L, Zipoli G (2003) Use of NOAA-AVHRR NDVI
447 images for the estimation of dynamic fire risk in Mediterranean areas. *Remote*
448 *Sensing of Environment* **86**, 187-197.
- 449 Ministerio de Medio Ambiente y Medio Rural y Marino (2008) Anuario de estadística.

- 450 Ministerio de Medio Ambiente (2006) Los incendios forestales en España. Decenio
451 1996-2005.
- 452 Moran MS, Clarke TR, Inoue Y, Vidal A (1994) Estimating crop water déficit using the
453 relation between surface-air temperatura and spectral vegetation index. *Remote*
454 *Sensing of Environment* **49**, 246-263.
- 455 Preisler HK, Burgan RE, Eidenshink JC, Klaver JM, Klaver RW (2009) Forecasting
456 distributions of large federal-lands fires utilizing satellite and gridded weather
457 information. *International Journal of Wildland Fire* **18**, 508-516.
- 458 Preisler HK, Chen S, Fujiola F, Benoit JW, Westerling AL (2008) Wildland fire
459 probabilities estimated from weather model-deduced monthly mean fire danger
460 indices. *International Journal of Wildland Fire* **17**, 305-316.
- 461 Rouse JW, Hass RH, Schell JA, Deering DW (1974) Monitoring vegetation systems in
462 the Grat Plains with ERTS. *Proceedings, third Earth Resources Technology*
463 *Satellite-1 Symposium, Greenbelt, NASA SP-351* (pp. 309-317).
- 464 Sánchez JM, Rubio E, López-Serrano FR, Caselles V, Bisquert MM (2009) Effects of
465 fire on surface energy fluxes in a central Spain Mediterranean forest. Ground
466 measurements and satellite monitoring. *Proceedings of the VII International*
467 *EARSeL Workshop, Matera (Italy)*, pp. 145-149.
- 468 Sellers PJ (1985) Canopy reflectance, photosynthesis and transpiration. *International*
469 *Journal of Remote Sensing* **6(8)**, 1335-1372.
- 470 Shneider P, Roberts DA, Kyriakidis PC (2008) A VARI-based relative greenness from
471 MODIS data for computing the Fire Potential Index. *Remote Sensing of*
472 *Environment* **113**, 1151-1167.

- 473 Stow D, Niphadkar M, Kaiser J (2005) MODIS-derived visible atmospherically
474 resistant index for monitoring chaparral moisture content. *International Journal*
475 *of Remote Sensing* **26**, 3867-3873.
- 476 Strahler A, Muchoney D, Borak J, Friedl M, Gopal S, Lambin E, Moody A (1999)
477 MODIS Land Cover Product Algorithm Theoretical Basis Document.
- 478 Verbesselt J, Jönsson P, Lhermitte S, Van Aardt J, Coppin P (2006) Evaluating satellite
479 and climate data-derived indices as fire risk indicators in savanna ecosystems.
480 *IEEE Transactions on Geosciences and Remote Sensing* **44**, 1622-1632.
- 481 Xunta de Galicia (2001) O bosque avanza. *Santiago de Compostela: Xunta de Galicia,*
482 *Consellería de Medio Ambiente.*
- 483 Yebra M, Chuvieco E, Riaño D (2008) Estimation of live fuel moisture content from
484 MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*
485 **148**, 523-536.
- 486 Yu GR, Miwa T, Nakayama K, Matsuoka N, Kon H (2000) A proposal for universal
487 formulas for estimating leaf water status of herbaceous and woody plants based
488 on spectral reflectance properties. *Plant and Soil* **227**, 47-58.

Table 1. MOD12 Q1 Land Cover Type 3 classification and combined categories for the separate analysis.

MOD12 Q1 Land Cover Type 3	Broad categories
Grasses/Cereal crops Broadleaf crops	Agricultural areas
Shrubs Savanna	Shrubland
Broadleaf forest Needleleaf forest	Forest (tree dominated)
Non-vegetated Urban Water	Non-vegetated areas

Table 2. Coefficients of the logistic regression.

Variables	B	E.T.	P(Wald)	Exp(B)
Δ EVI	-5.2	0.8	< 0.001	0.006
Period			< 0.001	
Period(1)	1.7	0.2	< 0.001	5.433
Period(2)	0.4	0.3	< 0.001	1.492
Period(3)	1.7	0.2	< 0.001	5.692
Period(4)	1.1	0.2	< 0.001	3.088
Period(5)	1.7	0.2	< 0.001	5.37
Period(6)	1.1	0.2	< 0.001	2.969
Period(7)	1	0.2	< 0.001	2.78
Period(8)	1.5	0.2	< 0.001	4.494
Period(9)	1.7	0.2	< 0.001	5.592
Period(10)	1.5	0.2	< 0.001	4.281
Period(11)	1.8	0.2	< 0.001	5.852
Period(12)	2.1	0.2	< 0.001	8.141
Period(13)	1.2	0.3	< 0.001	3.398
Period(14)	1.4	0.2	< 0.001	4.1
Period(15)	1.7	0.2	< 0.001	5.414
Period(16)	0	0		
Constant	-2.2	0.2	< 0.001	0.107

Table 3. Concordance levels for the logistic regression.

Observed		Predicted					
		Training			Test		
		Fire		Concordance	Fire		Concordance
		0	1		0	1	
No fire	0	2075	1365	60.3	2017	1400	59.0
Fire	1	612	885	59.1	665	855	56.3
Global concordance				60.0			58.2

Table 4. Hosmer-Lemeshow test.

	No fire		Fire		Total
	Observed	Estimated	Observed	Estimated	
1	447	439.421	47	54.579	494
2	391	399.338	103	94.662	494
3	379	375.324	115	118.676	494
4	366	360.149	128	133.851	494
5	343	352.361	151	141.639	494
6	329	339.903	165	154.097	494
7	325	328.555	170	166.445	495
8	325	307.876	170	187.124	495
9	278	286.933	216	207.067	494
10	257	250.140	232	238.860	489

P=0.408

CAPTIONS

Fig. 1. Location of the Galicia region (northwest Spain). Images of the Terra-MODIS product MOD13 Q1, corresponding to the period 10-25 June 2003: (a) NDVI, (b) EVI.

Fig. 2. 16-day cumulative fire events in Galicia averaged over 2001-2006.

Fig. 3. EVI images re-gridded to 10×10 km from their original resolution 250×250 m. Example corresponding to the MODIS composite August 29- September 13, 2003.

Fig. 4. Map of the cell-dominant land uses in Galicia.

Fig. 5. NDVI and EVI evolution for the year 2003.

Fig. 6. 16-day Δ EVI values in Galicia averaged over 2001-2006.

Fig. 6. Linear adjustment between the percentage of fire-affected cells and the EVI variation in the previous two weeks, for the 50% of the total temporal series available (using a random function).

Fig. 7. Comparison between the probability of fire occurrence predicted and observed.

Fig. 8. (a) Fire probability values for the different risk levels assigned. **(b)** Fire probability values versus the number of fire events per cell.

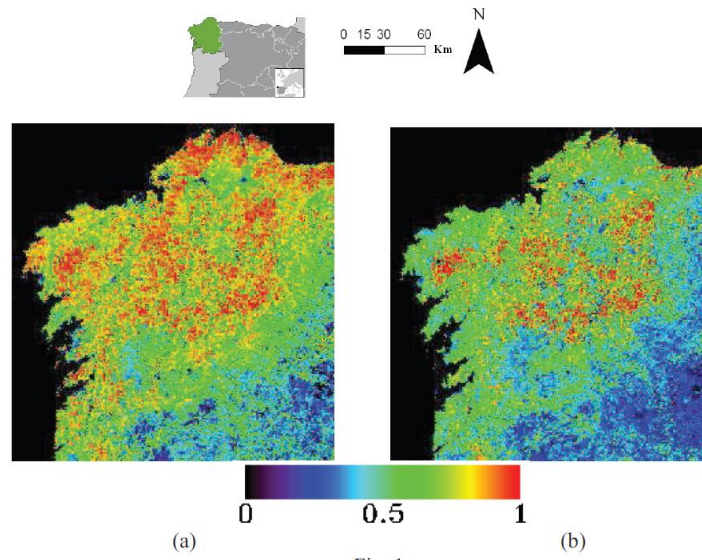


Fig. 1




Fig. 2

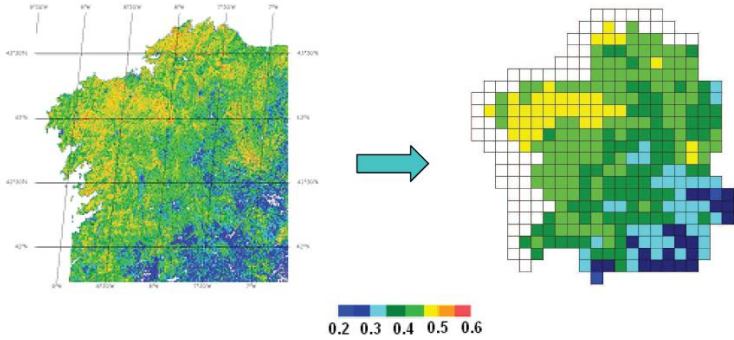


Fig. 3




Fig. 4




Fig. 5




Fig.6




Fig. 7

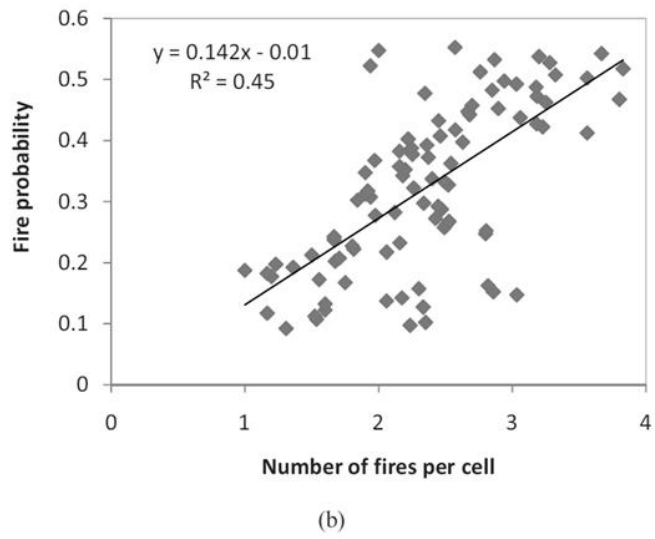
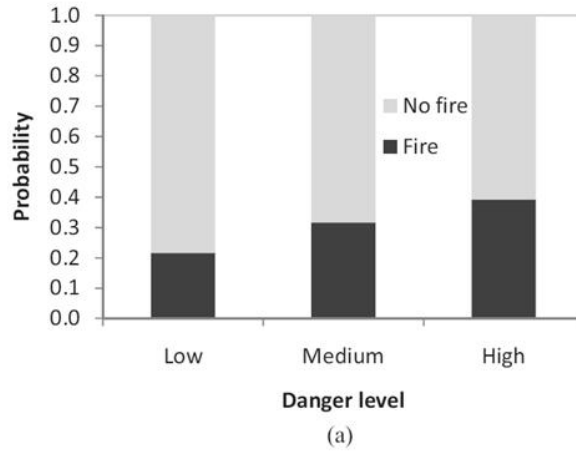


Fig. 8