

# Desarrollo de una metodología para la detección de cambios de la cubierta vegetal en series temporales de imágenes de satélite diarias. Aplicación a la detección de áreas quemadas

Moreno-Ruiz, J.A.\*<sup>1</sup>, Arbelo, M.<sup>2</sup>, García-Lázaro, J.R.<sup>1</sup>, Riaño-Arribas, D.<sup>3</sup>

<sup>1</sup>Grupo de Tratamiento de Imágenes, Departamento de Informática, Universidad de Almería, Ctra. Sacramento s/n, 04120 La Cañada de San Urbano, Almería, España.

<sup>2</sup>Grupo de Observación de la Tierra y la Atmósfera (GOTA), Departamento de Física FEES, Universidad de La Laguna, 38206 La Laguna, España.

<sup>3</sup>Center for Spatial Technologies and Remote Sensing (CSTARS), University of California, 250-N, The Barn, One Shields Avenue, Davis, CA 95616-8617, USA.

---

**Resumen:** Se ha desarrollado una metodología para la detección de cambios de la cubierta vegetal, a nivel de píxel, en series temporales de imágenes de satélites diarias mediante la utilización de un clasificador bayesiano. Dicha metodología ha sido aplicada satisfactoriamente a la detección de áreas quemadas en los bosques boreales de Norte América en el período 1981 a 2011, utilizando el conjunto de datos *Long Term Data Record* (LTDR) que constituye la serie temporal más larga de imágenes diarias de satélite a escala global, con una resolución espacial de 0,05° (~5 km). La metodología propuesta consta de varias etapas: 1) pre-procesamiento de las imágenes diarias y obtención de imágenes compuestas de  $n$  días; 2) construcción del espacio de las variables o atributos a considerar; 3) diseño del algoritmo, mediante la selección y refinamiento de los casos de entrenamiento; 4) obtención de los mapas de probabilidad relacionados con las clases temáticas a considerar; 5) post-procesamiento para mejorar los resultados obtenidos mediante la aplicación de múltiples técnicas (filtros, rangos, coherencia espacial, etc.). Los resultados finales obtenidos son comparados con los datos de referencia mediante métricas de exactitud derivadas de la matriz de error (errores de comisión y omisión, porcentaje de estimación) y de gráficos de dispersión (coeficiente de correlación y pendientes de la recta de regresión, etc.). La calidad de los resultados obtenidos al aplicar esta metodología a las imágenes LTDR para la detección de área quemada en la región boreal de Norte América mejora en términos de exactitud espacio-temporal a la de los otros dos productos de área quemada globales comparados (MCD45A1, BA GEOLAND-2) a pesar de que utilizan imágenes de mayor resolución espacial (y sólo disponibles a partir del año 2000): la estimación de área quemada total sobre la región de estudio en el periodo 2001-2011 fue de 28,56 millones de hectáreas según los datos de referencia y de 12,41, 138,43 y de 19,41 millones de hectáreas para los productos MCD45A1, BA GEOLAND-2 y BA-LTDR, respectivamente.

**Palabras clave:** bosque boreal, algoritmo áreas quemadas, redes bayesianas, series temporales.

## **Methodology for the detection of land cover changes in time series of daily satellite images. Application to burned area detection**

**Abstract:** We have developed a methodology for detection of observable phenomena at pixel level over time series of daily satellite images, based on using a Bayesian classifier. This methodology has been applied successfully to detect burned areas in the North American boreal forests using the LTDR dataset. The LTDR dataset represents the longest

\* Autor para la correspondencia: [jamoreno@ual.es](mailto:jamoreno@ual.es)

time series of global daily satellite images with  $0.05^\circ$  (~5 km) of spatial resolution. The proposed methodology has several stages: 1) pre-processing daily images to obtain composite images of  $n$  days; 2) building of space of statistical variables or attributes to consider; 3) designing an algorithm, by selecting and filtering the training cases; 4) obtaining probability maps related to the considered thematic classes; 5) post-processing to improve the results obtained by applying multiple techniques (filters, ranges, spatial coherence, etc.). The generated results are analyzed using accuracy metrics derived from the error matrix (commission and omission errors, percentage of estimation) and using scattering plots against reference data (correlation coefficient and slope of the regression line). The quality of the results obtained improves, in terms of spatial and timing accuracy, to other burned area products that use images of higher spatial resolution (500 m and 1 km), but they are only available after year 2000 as MCD45A1 and BA GEOLAND-2: the total burned area estimation for the study region for the years 2001-2011 was 28.56 millions of ha according to reference data and 12.41, 138.43 and 19.41 millions of ha for the MCD45A1, BA GEOLAND-2 and BA-LTDR burned area products, respectively. .

**Key words:** boreal forest, burned area algorithm, bayesian network, time series.

---

## 1. Introducción

El análisis de los datos obtenidos en teledetección se ha convertido a lo largo de las tres últimas décadas en una herramienta fundamental para el estudio de la dinámica de diversas variables ambientales, tanto a escala regional como global (Riaño *et al.*, 2007). Series temporales de imágenes procedentes de nuevos sensores de órbita polar, tales como *MODerate resolution Imaging Spectroradiometer* (MODIS) puesto en funcionamiento a partir del año 2000, con mejores resoluciones espectrales y espaciales que los disponibles hasta esa fecha (por ejemplo, *Advanced Very High Resolution Radiometer*), generan diariamente un volumen ingente de información, cuyo procesamiento requiere necesariamente de técnicas computarizadas. En este sentido, presenciamos una continua evolución de dichas tecnologías informáticas, tanto a nivel de potencia de cómputo y almacenamiento del *hardware*, como también del desarrollo de *software* y de la puesta en funcionamiento de nuevos algoritmos y aplicaciones informáticas, que posibilitan conjuntamente poder abordar con éxito estos nuevos retos. Frente a los primeros enfoques tradicionales de clasificación no supervisados (tales como IsoData ó K-means) y supervisados (paralelepípedo) (Barbosa *et al.*, 1998; Riaño *et al.*, 2007; Chuvieco *et al.*, 2008), han surgido nuevos métodos de aprendizaje máquina ("*learning machine*") basados en árboles de decisión, redes bayesianas, sistemas difusos o redes neuronales, los cuales han sido aplicados a las imágenes de satélite de forma exitosa en diversos contextos (Al-Rawi *et al.*, 2001; Zhan *et al.*, 2002

Moreno Ruiz *et al.*, 2012; García Lázaro *et al.*, 2013; Moreno Ruiz *et al.*, 2014).

La detección de cambios en la cubierta vegetal utilizando imágenes de satélite puede ser utilizada en múltiples aplicaciones, tales como estudios de deforestación, desertificación, detección de fuegos y de áreas quemadas, etc. El diseño de un algoritmo para tal fin no sólo requiere de un conocimiento preciso de las características espectrales del mismo, sino también de cómo éstas varían a lo largo del tiempo. Es más, si se pretende que el algoritmo a diseñar se pueda aplicar de forma generalizada, éste debería tener en cuenta todos los factores perturbadores de las medidas radiométricas de la zona de estudio, no sólo los factores directos como consecuencia de la aparición del cambio de la cobertura vegetal a detectar, sino también los indirectos debido a la incertidumbre presente en los datos (Crosetto *et al.*, 2001). Su detección depende fundamentalmente de la propia escena de estudio, ya que la variabilidad de su respuesta espectral no sólo está sujeta a los cambios en la estructura de su naturaleza cuando ésta se ve afectada, sino que también puede ser debida a las condiciones atmosféricas e incluso al propio instrumento de medida. Por ejemplo, la precisión en la geo-referenciación, la degradación del sistema sensor/satélite, la ausencia de datos o la baja calidad de los mismos puede afectar a dicha variabilidad, que en la mayoría de los casos, no es tenida en cuenta o es considerada despreciable (Moreno-Ruiz *et al.*, 2009).

Una vez conocidos los patrones de comportamiento espectral del cambio a detectar de la cubierta

vegetal, se deberían considerar a continuación múltiples variables para su análisis y estudio. Además, se deben considerar no sólo las variables procedentes de las medidas o bandas radiométricas originales de los sensores de teledetección, sino también las posibles variables o índices derivados que se obtienen a partir de las mismas. A continuación, se deberían seleccionar aquellas variables que permitan describirlo de la mejor forma posible, así como la evolución temporal de su comportamiento (Foody, 2002). Una vez seleccionado el conjunto de variables que hipotéticamente mejor lo caracterizan, se deberían calcular sus respectivos valores para un conjunto de casos ó muestras de entrenamiento/validación, los cuales son necesarios para el algoritmo supervisado de detección (por ejemplo, casos conocidos de presencia y ausencia del cambio a detectar, cuando se utiliza un esquema dicotómico de clasificación).

El objetivo de este trabajo ha sido desarrollar una metodología para la detección de cambios de la cubierta vegetal en series temporales de imágenes de satélites diarias, implementada a través de una herramienta diseñada ex profeso, y que ha sido aplicada particularmente al caso de la detección de áreas quemadas en la región de los bosques boreales de Norte América, utilizando datos diarios del conjunto *Long Term Data Record* (LTDR) versión 3, con  $0,05^\circ$  ( $\sim 5$  km) de resolución espacial, derivados a partir de las bandas radiométricas originales (reflectividades y temperaturas de brillo) teledetectadas por los dos sensores que se indican a continuación (Pedelty *et al.*, 2007):

- a) En el período 1981-2000: *Advanced Very High Resolution Radiometer* (AVHRR), a bordo de los satélites de *National Oceanic and Atmospheric Administration* (NOAA).
- b) En el período 2001-2011: *MODerate resolution Imaging Spectroradiometer* (MODIS), a bordo de los satélites Aqua y Terra.


El algoritmo de detección de cambios de la cubierta vegetal en series temporales de imágenes diarias de satélite utiliza una estrategia algorítmica supervisada basada en redes bayesianas (Bayes, 1763). Se ha utilizado un clasificador Bayesiano tipo Naïve Bayes, el cual, a partir del conjunto de casos de entrenamiento, obtiene un modelo de red bayesiana que permite asignar a cada píxel una probabilidad de pertenencia a cada una de las

clases temáticas definidas, atendiendo a los valores de dichas variables. El resultado generado por el algoritmo bayesiano es un mapa de probabilidades asociadas a la detección del cambio en cada píxel de la imagen. Para la construcción del algoritmo de detección se ha utilizado el software WEKA de la Universidad de Waikato (Hall *et al.*, 2009), el cual permite evaluar diversas alternativas algorítmicas.

## 2. Métodos y Datos

### 2.1. Zona de estudio e imágenes utilizadas

La zona de estudio elegida para la aplicación de la metodología propuesta a la detección de área quemada en series temporales de imágenes de satélite diarias ha sido la región de Bosque Boreal de Norte América (UL:  $70^\circ\text{N}$ ,  $-168,5^\circ\text{E}$ ; LR:  $45^\circ\text{N}$ ,  $-50^\circ\text{E}$ ). En dicha región se dispone de varias bases de datos con información bastante precisa de las áreas quemadas en la últimas décadas, las cuales incluyen los datos oficiales registrados por los servicios forestales de Canadá, *Canadian Forest Service National Fire Database* (CFSNFD), y de Alaska, *Alaska Fire Service* (AFS). Dicha información será utilizada como referencia para el entrenamiento del algoritmo y para la validación de los resultados obtenidos.



**Figura 1.** La región de estudio comprende todo el bosque boreal de Norteamérica ( $70^\circ\text{N}$ ,  $-168,5^\circ\text{E}$ ;  $45^\circ\text{N}$ ,  $-50^\circ\text{E}$ ). El bosque boreal está representado con color verde y todas las demás cubiertas de tierra con color marrón. Para la interpretación de los colores consultar edición digital, <http://dx.doi.org/10.4995/raet.2014.2280>.

La serie temporal de imágenes que se ha considerado ha sido la versión 3 del conjunto de datos diario *Long Term Data Record* (LTDR). Dicho conjunto de datos fue generado originariamente a

**Tabla 1.** Descripción de la versión 3 del conjunto de datos *Long Term Data Record* (LTDR). El tipo de dato utilizado es entero de 16 bits (2 bytes), y el factor de escala es el número por el que se debe dividir el entero para recuperar el valor físico en sus unidades correspondientes.

AVHRR-LTDR (1981-1999)				
Banda	Descripción	Ancho de banda ( $\mu\text{m}$ )	Unidades	Factor de escala
SREFL_CH1	Reflectividad de superficie para canal 1	0,58 – 0,68		$10^4$
SREFL_CH2	Reflectividad de superficie para canal 2	0,725 – 1,000		$10^4$
SREFL_CH3	Reflectividad de superficie para canal 3	3,55 – 3,93		$10^4$
BT_CH3	Temperatura de brillo para canal 3	3,55 – 3,93	Kelvin	10
BT_CH4	Temperatura de brillo para canal 4	10,30 – 11,30	Kelvin	10
BT_CH5	Temperatura de brillo para canal 5	11,50 – 12,50	Kelvin	10
SZEN	Ángulo cenital solar		Grados	$10^2$
VZEN	Ángulo cenital de observación		Grados	$10^2$
RELAZ	Azimut relativo		Grados	$10^2$
QA	Campo de evaluación de calidad			
MODIS-LTDR (2001-)				
Banda	Descripción	Ancho de banda ( $\mu\text{m}$ )	Unidades	Factor de escala
BRDF_B1	Reflectividad de superficie para canal 1	0,620 – 0,670		$10^4$
BRDF_B2	Reflectividad de superficie para canal 2	0,841 – 0,876		$10^4$
BRDF_B7	Reflectividad de superficie para canal 7	2,105 – 2,155		$10^4$
Internal CM	Máscara binaria de áreas sin datos			
NDVI	Índice de Vegetación Diferencial Normalizado			
QA	Campo de evaluación de calidad			
BT_B31	Temperatura de brillo para canal 31	10,780 – 11,280	Kelvin	10
BT_B32	Temperatura de brillo para canal 32	11,770 – 12,270	Kelvin	10

partir de imágenes AVHRR-GAC, las cuales fueron recalibradas, aplicando correcciones atmosféricas y geométricas, y finalmente re-proyectados a LAT-LON de  $0,05^\circ$  ( $\sim 5$  km) de resolución espacial (Pedelty *et al.*, 2007). A partir del año 2000, el conjunto de datos LTDR se generó a partir de datos del sensor MODIS, a bordo de los satélites Aqua y Terra, manteniendo la resolución espacial de la serie temporal de datos, pero con una ligera modificación en las bandas espectrales (se sustituyó la banda MIR por la banda TIR). Los datos fueron descargados del servidor web de la NASA (<http://ltdr.nascom.nasa.gov/cgi-bin/ltdr/ltdrPage.cgi?fileName=products>, último acceso el 26/07/2014). En la Tabla 1 se resumen las principales características del conjunto de datos LTDR versión 3.

Para la validación de los resultados, se ha construido un conjunto de datos de referencia de áreas quemadas a partir de los datos oficiales registrados por *Canadian Forest Service National Fire Database* (CFSNFD) y *Alaska Fire Service* (AFS). También se han comparado los resultados obtenidos con resultados de dos productos oficiales de área quemada: *Moderate Resolution Imaging Spectroradiometer* (MODIS) *burned area product* (MCD45A1), y *burned area GEOLAND-2 product* (BA GEOLAND-2). En la Tabla 2 se resumen las principales características de estos dos productos de área quemada.

El producto MCD45A1, deriva del sensor MODIS con 500 m de resolución espacial (Roy *et al.*, 2005, 2008). El producto BA GEOLAND-2 deriva

**Tabla 2.** Principales características de los productos de área quemada derivados de MODIS (MCD45A1) y SPOT-VEGETATION (BA GEOLAND-2).

Producto de Área Quemada	MCD45A1	BA GEOLAND-2
Cubierta	Global	Global
Sensor	Terra-MODIS y Aqua-MODIS	SPOT-VEGETATION
Intervalo temporal	2000-Actualidad	2001-Actualidad
Resolución espacial	500 m	1 km
Resolución temporal	Diario	10 días
Algoritmo	(Roy <i>et al.</i> , 2008; Roy <i>et al.</i> , 2005)	(Tansey <i>et al.</i> , 2012)

del sensor VEGETATION a bordo de los satélites SPOT con 1 km de resolución espacial (Tansey *et al.*, 2012). Las resoluciones espacial, temporal, espectral y radiométrica de ambos sensores se describen en la Tabla 3.

Se han construido mapas anuales de áreas quemadas para estos dos productos en sus respectivas resoluciones nativas para la región de estudio para

el periodo 2001-2011, y en el periodo 1981-2011 para los datos de referencia. A continuación, y para poder comparar los resultados y minimizar distorsiones espaciales manteniendo formas cuadradas equivalentes, todos los mapas anuales generados fueron re-proyectados a una proyección *Lambert Conformal Conic* (Chuvieco *et al.*, 2008).

**Tabla 3.** Principales características de los sistemas satélite-sensor Terra-MODIS y SPOT-VEGETATION.

Satélite-sensor	Órbita	Bandas Espectrales				
		Banda	Ancho de banda ( $\mu\text{m}$ )	Resolución espacial (m)	Resolución radiométrica	
Terra-MODIS	Circular	1	0,620 – 0,670	250 m	12 bits	
	Síncrona con el sol	2	0,841 – 0,876	250 m		
	Casi polar	3	0,459 – 0,479	500 m		
	Altitud: 705 km	4	0,545 – 0,565	500 m		
	Inclinación: 98,2°	5	1,230 – 1,250	500 m		
	Período Rev.: 98,9 min	6	1,628 – 1,652	500 m		
	Res. Temporal: 1 día		7	2,105 – 2,155		500 m
			8	0,405 – 0,420		1000 m
			9	0,438 – 0,448		1000 m
			10	0,483 – 0,493		1000 m
			11	0,526 – 0,536		1000 m
			12	0,546 – 0,556		1000 m
			13	0,662 – 0,672		1000 m
			14	0,673 – 0,683		1000 m
			15	0,743 – 0,753		1000 m
			16	0,862 – 0,877		1000 m
			17	0,890 – 0,920		1000 m
			18	0,931 – 0,941		1000 m
			19	0,915 – 0,965		1000 m
			20	3,660 – 3,840		1000 m
			21	3,929 – 3,989		1000 m
			22	3,929 – 3,989		1000 m
			23	4,020 – 4,080		1000 m
			24	4,433 – 4,498		1000 m
			25	4,482 – 4,549		1000 m
			26	1,360 – 1,390		1000 m
			27	6,535 – 6,895		1000 m
			28	7,175 – 7,475		1000 m
			29	8,400 – 8,700		1000 m
			30	9,580 – 9,880		1000 m
			31	10,780 – 11,280		1000 m
			32	11,770 – 12,270		1000 m
			33	13,185 – 13,485		1000 m
			34	13,485 – 13,785		1000 m
			35	13,785 – 14,085		1000 m
			36	14,085 – 14,385		1000 m
SPOT-VEGETATION	Circular	1	0,45 – 0,52	1000 m	10 bits	
	Síncrona con el sol	2	0,61 – 0,68	1000 m		
	Casi polar	3	0,78 – 0,89	1000 m		
	Altitud: 822 km	4	1,58 – 1,75	1000 m		
	Inclinación: 98,7°					
	Período: 101,4 min Res. Temporal: 24 h					

## 2.2. Metodología de detección de cambios de la cubierta vegetal

Para la detección de cambios en la cubierta vegetal a partir de series temporales de imágenes de satélite diarias, proponemos la siguiente metodología basada en una secuencia de etapas. Para llevarlas a cabo, se ha diseñado una herramienta software que permite la implementación efectiva y su integración en una cadena de procesamiento. Las etapas de que consta esta metodología son las descritas a continuación:

1. Pre-procesamiento (composición temporal de imágenes): el objetivo de este primer paso consiste en eliminar principalmente los efectos atmosféricos presentes en las imágenes que interfieren en la detección del cambio. Previamente se elige la región de estudio y se seleccionan, del conjunto de datos diarios, las bandas espectrales que se utilizarán en su proceso de detección. Igualmente, se establece el periodo y criterio de composición por el que se crearán las imágenes compuestas a partir de las imágenes diarias (Barbosa *et al.*, 1998; Chuvieco *et al.*, 2005).
2. Selección del esquema de clasificación y preparación de datos de referencia para entrenamiento y validación: a partir de datos geo-referenciados y validados obtenidos de productos de datos disponibles con mejor resolución espacial, se construye una imagen de referencia, en la proyección y resolución del conjunto de datos considerado. Previamente se establece el esquema de clasificación (clases temáticas) a considerar (Foody, 2002). En los datos de referencia se almacena la fecha de observación e información relevante asociada (p. ej.: grado de intensidad, tipo de cubierta vegetal, etc.).
3. Construcción del conjunto de casos de entrenamiento: de la imagen de referencia se seleccionan aquellos píxeles de la región de estudio que cumplen el criterio de que su información asociada sea del tipo adecuado y que la fecha de observación se encuentre en el periodo de estudio.
4. Determinación del conjunto de variables más óptimo: se extraen, del conjunto de datos compuesto, las variables (bandas espectrales originales e índices derivados) que mejor detecten el cambio en cada uno de los píxeles seleccionados para los periodos previos, durante y posterior a su aparición. La duración y localización en el tiempo de dichos periodos están relacionadas con la información asociada al píxel y como ésta evoluciona en el tiempo. Se calculan estadísticos (máximos, mínimos, valores centrales, valores de dispersión, comparaciones relativas, correlaciones,...) para las variables que se consideren más adecuadas, y para tres periodos temporales (antes, durante y después de la aparición del cambio).
5. Diseño del algoritmo: mediante un clasificador basado en redes bayesianas se construye, a partir del conjunto de entrenamiento, el algoritmo de detección/clasificación, que aplicado al conjunto de variables seleccionadas, produce un mapa con información sobre la probabilidad de que un píxel de la imagen se vea afectado por el cambio a detectar. Los pasos principales a realizar en esta etapa son:
  - a) Refinamiento de los casos de entrenamiento: se requiere un proceso iterativo de refinamiento sucesivo en los casos de prueba hasta conseguir un clasificador que maximice el número de aciertos con el menor error posible. Este proceso consiste en ir depurando la selección de casos de prueba atendiendo a los aciertos/fallos del clasificador. Dichos fallos se pueden deber a múltiples causas: errores de geo-referenciación entre los archivos de composición del conjunto de datos, efectos atmosféricos que no hayan sido eliminados de la imagen compuesta y por tanto pueden influir en las estadísticas, diferencias de geo-localización entre los casos de referencia y el conjunto de datos debido al cambio de proyección. Pueden surgir también errores de clasificación debidos a errores en los propios datos de referencia o efectos derivados del cambio de resolución que podrían establecer referencias incorrectas o parcialmente incorrectas en el conjunto de los casos de uso.
  - b) Con objeto de minimizar el proceso de refinamiento se parte de una sub-selección previa de la escena de estudio atendiendo a criterios radiométricos que teóricamente tendría que cumplir cada caso en los periodos de tiempo antes, durante y después del

cambio. Los criterios de selección radiométricos se especifican de forma que el número de casos seleccionados que se obtenga sea similar al número de los casos de referencia. El conjunto de casos formado por la intersección entre dicha sub-selección y los de referencia se utiliza como conjunto de partida de entrenamiento. Un mayor número de casos intersección podría mejorar la exactitud del resultado final.

- c) Interpretación de los mapas de probabilidad: con el clasificador de redes bayesianas se obtiene la probabilidad con la que un píxel está afectado por el cambio. Probabilidades muy altas, superiores a un determinado umbral (a determinar empíricamente), estarán relacionadas con píxeles totalmente afectados; mientras que probabilidades muy bajas (por debajo de un determinado umbral) estarán relacionadas con píxeles no afectados. Extrapolando los resultados, se podría decir que probabilidades entre ambos rangos podrían estar relacionadas con píxeles parcialmente afectados. Se obtienen así mapas de píxeles con al menos 3 categorías de estados: *afectado*, *parcialmente afectado* y *no afectado*.
6. Post-procesamiento I (coherencia temporal): para mejorar el resultado que se obtiene con el clasificador, a modo de filtro, se podrían introducir condiciones simultáneas de varias variables así como relaciones temporales que especificarían cual debería ser el comportamiento relativo entre ellas, o cualquier otro tipo de información contrastada no relacionada directamente con la radiometría del conjunto de datos (ej. mapas de clasificación obtenidos a partir de otras fuentes). También se podrían aplicar una serie de reglas (relajadas) que eviten que situaciones inconsistentes pudieran albergar una cierta probabilidad.
7. Post-procesamiento II (coherencia espacial): el último paso supone un post-procesamiento de los píxeles atendiendo al estado de sus vecinos más próximos. Para que sea independiente de la forma en la que se recorren los píxeles, es necesario un procesamiento en paralelo. Se comprueba simultáneamente el estado de cada píxel y el de sus vecinos más próximos, y mediante una serie de reglas de transición del tipo

de los autómatas celulares se obtiene su nuevo estado (Burks, 1970). Los cambios de estado de dichos píxeles, podrían repercutir, a su vez, en el estado de los píxeles vecinos, lo que provocaría un proceso encadenado de cambios. El proceso se repite hasta que o bien el resultado sea estable y no se produzcan más cambios, o bien se alcance un  $n^\circ$  máximo de iteraciones prefijado.

### 2.3. Aplicación a la detección de áreas quemadas en Norte América

La metodología propuesta se aplicó a la detección de áreas quemadas en los bosques boreales de Norte América utilizando series temporales de imágenes de satélite de baja resolución. A continuación se presentan los aspectos más destacados en las diferentes etapas.

1. Pre-procesamiento de la serie temporal: del conjunto de datos diarios LTDR originales, almacenados en archivos con formato *Hierarchical Data Format* (HDF), se extrajeron las bandas de reflectividad de superficie para los canales 1 y 2, de temperatura de brillo para el canal 3/31 y del campo de evaluación de calidad (QA), obteniéndose archivos diarios con formato secuencial de bandas (BSQ). De cada 10 archivos diarios BSQ se obtuvo un archivo compuesto seleccionando, para cada píxel de la imagen compuesta, los datos del día de mayor temperatura de brillo del canal 3/31 (3,75  $\mu\text{m}$  para el sensor AVHRR-LTDR, y 11,03  $\mu\text{m}$  para el sensor MODIS-LTDR), teniendo en cuenta el bit de calidad para filtrar valores no válidos en las medidas. Para cada año de la serie temporal, sólo se consideraron los compuestos comprendidos entre el 21 de abril y el 31 de septiembre. Adicionalmente, y con el fin de eliminar los posibles píxeles con nieve de esos compuestos, los píxeles con reflectividad del canal 1 (0,63  $\mu\text{m}$ ,  $\rho_1$ ) mayor que 0,15 y temperatura de brillo inferior a 288 K también se filtraron.
2. Esquema de clasificación, zona de estudio y datos de referencia: para la detección de área quemada a nivel de píxel se ha utilizado un esquema de clasificación dicotómico, siendo las clases temáticas a considerar *Quemada* y *No quemada*. La zona de estudio elegida ha sido

la región de Bosque Boreal de Norte América (esquina superior izquierda: 70°N, -168,5°E; esquina inferior derecha: 45°N, -50°E). Se ha construido un conjunto de datos de referencia de áreas quemadas a partir de los datos oficiales registrados por los servicios forestales de Canadá (CFSNFD), y de Alaska (AFS).

3. Construcción del conjunto de casos de entrenamiento: Para el entrenamiento del algoritmo se utilizó la región de Alaska (esquina superior izquierda: 70°N, -168,5°E; esquina inferior derecha: 60°N, -141°E) y el año 1990, por la gran cantidad de incendios y de áreas quemadas registradas. Los datos de entrenamiento están constituidos por 690 píxeles quemados y 3756 píxeles no quemados. En la Tabla 4 se indican los principales estadísticos descriptivos (media y desviación estándar) del conjunto de entrenamiento para las variables seleccionadas descritas en el siguiente apartado.
4. Selección de variables: En el bosque boreal la vegetación tarda en recuperarse varios años incluso más de una década, en nuestro caso hemos establecido que se analizará también el año anterior y posterior al incendio, con una duración de 2 meses para los periodos pre-fuego y post-fuego de cada año, a partir de la hipotética fecha de ignición. El instante del fuego viene determinado (Figura 2) por el valor del máximo del índice *Burn Boreal Forest Index* (BBFI) derivado a partir de las bandas radiométricas  $\rho_2$  (0,83  $\mu\text{m}$ ) y  $T_3$  (~3,75  $\mu\text{m}/11,03 \mu\text{m}$ ), cuya fórmula es (Moreno Ruiz et al., 2012):

$$\text{BBFI} = \frac{1}{\rho_2} + \frac{T_3}{2}$$

El estudio del comportamiento radiométrico de la evolución del fuego y su relación con los posibles índices nos ha llevado finalmente a seleccionar las 12 variables que aparecen descritas en la Tabla 4, las cuales se agrupan en 3 categorías:

- 1ª categoría: para la detección de píxeles cuya clase sea no quemada (con vegetación o suelo desnudo) en el año anterior al incendio, se utilizaron las variables (1, 2, 6, y 9). Estas variables miden las diferencias de las medianas de los índices GEMI (Pinty et al., 1992), BBFI e infrarrojo medio (NIR) entre el periodo post-fuego del año del incendio y el año anterior, así como el valor máximo del índice BBFI del año anterior al incendio.
- 2ª categoría: para la detección de píxeles cuya clase sea quemada que permanecieron en esta clase en el año después del incendio, se utilizaron las variables (3, 7 y 10). Estas variables miden el máximo de BBFI y de la temperatura  $T_3$  en el año posterior al incendio, junto con la diferencia de las medianas del índice GEMI entre el año del incendio y el año posterior.
- 3ª categoría: para la detección de píxeles cuya clase sea quemada con vegetación en el año del incendio, se utilizaron las variables (4, 5, 7, 8, 11 y 12). Estas variables miden respectivamente los máximos de BBFI, GEMI y  $T_3$  y el mínimo del infrarrojo medio en el año del incendio, y las diferencias de las medianas de GEMI antes y después del incendio en el año del incendio.



**Figura 2.** Esquema de subdivisión temporal para el cálculo de la estadística sobre las variables seleccionadas en el clasificador bayesiano.



**Tabla 4.** Descripción de las variables que utiliza la red bayesiana y su significancia estadística. Rango válido de los valores de las clases *quemado* y *no quemado* para cada una de ellas y las respectivas funciones de densidad de probabilidad para la región de entrenamiento de Alaska en el año 1990. (690 muestras “quemado” y 3756 muestras “no quemado”).

Id.	Descripción	Significancia Estadística	Valor Inferior	Valor Superior	Quemado		No Quemado	
					Media	Desv.	Media	Desv.
Nº1	Umbral relativo de la diferencia entre la mediana del GEMI (Pinty <i>et al.</i> , 1992) en el período post-fuego para el año del incendio y el año anterior.	0,1535			0,168	0,072	0,06	0,069
Nº2	Umbral relativo de la diferencia entre la pendiente de los datos BBFI en el período post-fuego del año del incendio y el año anterior.	0,0914			-1,308	1,194	-0,179	0,806
Nº3	Umbral absoluto del máximo del índice BBFI en el año después del incendio.	0,1298	158	180	168,022	3,574	158,804	3,189
Nº4	Umbral absoluto de la media del índice de GEMI en el período post-incendio en el año del incendio.	0,1628	0,23	0,48	0,362	0,067	0,457	0,068
Nº5	Umbral absoluto del máximo del índice BBFI para el año del incendio.	0,0647	158	190	166,379	5,021	158,474	2,508
Nº6	Umbral relativo de la diferencia entre el valor mínimo de la banda del Infrarrojo Medio en el período post-fuego para el año del incendio y el año anterior.	0,064	-0,18	0	-0,098	0,037	-0,049	0,047
Nº7	Umbral relativo de la diferencia entre la mediana del índice GEMI en el período pre-incendio para el año del incendio y el año posterior.	0,1317			0,175	0,074	0,075	0,095
Nº8	Umbral absoluto del máximo del canal de temperatura T3 para el año del incendio.	0,0593	298	322	309,9	3,626	305,28	3,389
Nº9	Umbral absoluto del máximo del índice BBFI para el año anterior.	0,0504	153	162	156,882	1,693	156,922	4,379
Nº10	Umbral absoluto del máximo del canal de temperatura T3 para el año posterior al incendio.	0,0921	300	322	316,327	3,438	306,303	4,302
Nº11	Umbral relativo de la diferencia entre la mediana del GEMI en los períodos Pre-Fuego y Post-incendio para el año de incendio.	0,1567			0,171	0,078	0,041	0,078
Nº12	Umbral absoluto del mínimo de la banda del Infrarrojo Medio para el año del incendio.	0,1167	0,025	0,15	0,087	0,026	0,0142	0,025

Adicionalmente, a las muestras de entrenamiento se les ha exigido que tengan valores de las respectivas variables dentro del intervalo (valor inferior, valor superior) indicado en la Tabla 4.

5. Diseño del algoritmo de clasificación: a partir del conjunto de casos de entrenamiento seleccionado, se ha construido un archivo de datos con formato compatible con el paquete de software WEKA (Hall *et al.*, 2009), en el que aparece el valor para cada variable junto con la clase

temática a la que pertenece (*quemado* o *no quemado*). Del resultado de aplicar el clasificador Bayes-Net en el paquete WEKA al conjunto de casos de entrenamiento se obtiene un algoritmo que permite determinar la probabilidad de un píxel de pertenecer a una determinada clase en base a las probabilidades parciales de cada una de las variables consideradas.

Una vez elegido el mejor modelo de clasificación atendiendo al error que se comete en la clasificación del propio conjunto de entrenamiento (mediante un proceso de refinamiento de casos de entrenamiento y/o inserción/eliminación de variables), éste se aplica sobre el conjunto de datos en su totalidad, obteniéndose un mapa de probabilidades: cada variable tiene una probabilidad asociada dependiendo de la clase a la que pertenece (*quemado*, *no-quemado*). El mapa de probabilidades se obtiene al normalizar la probabilidad conjunta de todas las variables (tomando como positivas las que pertenezcan a la clase *quemado* y como negativas a la clase *no quemado*).

La discretización de los intervalos de probabilidad para asociarlos a las clases temáticas (*quemado*, *no-quemado*, *parcialmente-quemado*), se realiza ajustando el número total de píxeles quemados a partir de una determinada probabilidad (utilizando un histograma) a la estimación de área quemada que se obtiene en la zona de estudio. En este caso, hemos utilizado el criterio de que sólo los píxeles con probabilidad positiva son considerados *quemados*.

6. Post-procesamiento: para mejorar el resultado final, en la etapa de post-procesamiento exigimos una coherencia espacial utilizando un proceso de filtrado basado en la teoría de autómatas celulares (Burks, 1970). Se parte de un estado inicial de clasificación, se aplican reiteradamente una serie de reglas de transición hasta que se llega a un estado final. Las reglas de transición que hemos elegido en nuestro caso han sido:

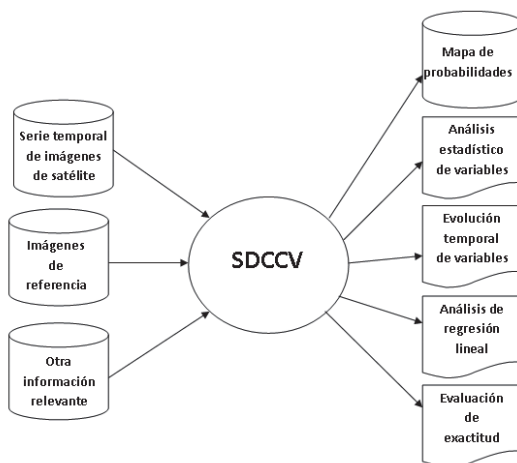
- Un píxel cuya clase sea Totalmente Quemado permanece en su estado si tiene al menos un vecino clasificado como Totalmente Quemado o Parcialmente Quemado. En caso contrario su estado pasa a ser Parcialmente Quemado.

- Un píxel cuya clase sea Parcialmente Quemado pasa al estado Totalmente Quemado si tiene al menos un vecino clasificado como Totalmente Quemado y dos o más vecinos clasificados como Parcialmente Quemados.

### 3. Resultados y Discusión

#### 3.1. Herramienta de detección de cambios de la cubierta vegetal

Se ha diseñado un software ex profeso que permite implementar la metodología para la detección de cambios de la cubierta vegetal en series temporales de imágenes de satélite diarias, al que hemos denominado SDCCV. En la Figura 3 se describe el diagrama de contexto de la herramienta diseñada para implementar y automatizar la metodología propuesta, donde se presentan a la izquierda las principales entradas de elementos de información a la herramienta SDCCV (serie temporal de imágenes, datos de referencia, otra información relevante tal como mapas temáticos de cubierta terrestre). A la derecha aparecen las salidas principales de elementos de información y resultados generados (mapas de probabilidades de pertenencia a las clases temáticas, análisis estadísticos de variables, gráficos detallados de evolución temporal de variables para un píxel determinado, informes de



**Figura 3.** Diagrama de contexto de la herramienta SDCCV desarrollada para la automatización de la metodología de detección de cambios en series temporales de imágenes de satélite.

evaluación de exactitud de los mapas temáticos generados, gráficos de dispersión y análisis de regresión lineal,...).

El software SDCCV ha sido desarrollado en lenguaje de programación C# usando el entorno de desarrollo integrado (IDE) de Microsoft Visual Studio 2013. La arquitectura interna de SDCCV (Figura 4) consta de múltiples módulos que desarrollan los diferentes pasos de la metodología propuesta (adquisición de datos, pre-procesamiento, composición de imágenes, entrenamiento, selección de variables, entrenamiento del algoritmo, post-procesamiento, generación de resultados).

Los diferentes módulos funcionales que constituyen la herramienta SDCCV se integran a través de una interfaz gráfica de usuario (GUI) basada en formularios estándar organizados jerárquicamente. En la Figura 5 se muestran diferentes capturas de pantalla de la ejecución de la herramienta SDCCV, donde se presentan varios formularios con los que se ha interactuado para la detección de área quemada en Norte América. El denominado

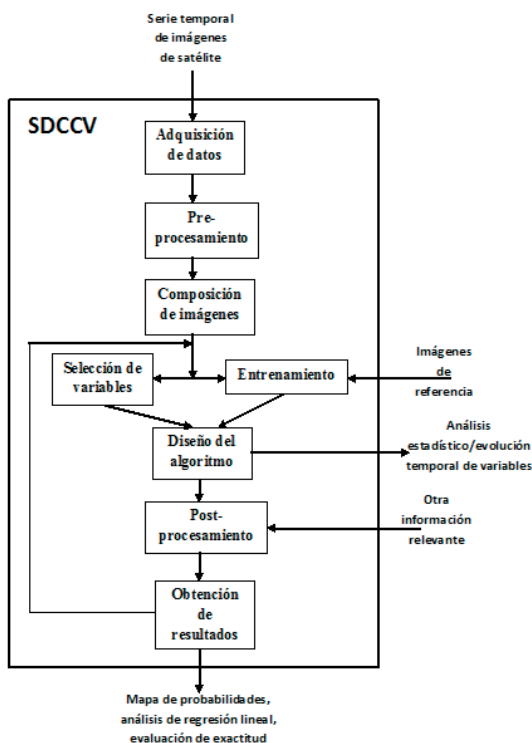
formulario principal (*Main Form*) es el primer formulario que se presenta al usuario al iniciar la aplicación, e incluye en su barra de menú las opciones principales de la herramienta. La segunda captura de pantalla muestra los detalles del formulario de composición de imágenes, en el que se puede seleccionar la región del estudio, el tipo de imagen, el criterio de composición, rango temporal y otros parámetros configurables. La tercera captura de pantalla muestra los detalles del formulario de entrenamiento, donde destaca en la parte derecha la selección de variables a utilizar por el clasificador, y en la parte izquierda diversas opciones/parámetros de configuración para la generación de los archivos de datos de entrenamiento e intercambio para el software WEKA (en formato ARFF), a partir del cual se obtiene el modelo de clasificación bayesiano. Las siguientes capturas de pantalla muestran algunas de las funcionalidades del formulario de análisis estadístico, donde aparecen múltiples campos que incluyen diferentes opciones para la configuración de los análisis de datos a realizar, modificación del comportamiento del algoritmo, filtros sobre las variables del modelo bayesiano y de las etapas de post-procesamiento, visualización gráfica de los resultados obtenidos, en términos de probabilidad conjunta y para cada una de las variables que intervienen en el modelo, etc.

La arquitectura modular de la herramienta SDCCV facilita su mantenimiento frente a modificaciones para corrección de errores, mejoras de rendimiento, así como futuras ampliaciones funcionales tales como la incorporación de nuevas estrategias algorítmicas e integración de herramientas estándar de análisis de datos y visualización de resultados.

### 3.2. Mapas anuales de área quemada en Norte América (1981-2011)

La Figura 6 muestra la distribución espacial de las áreas quemadas en Norte América obtenidas al aplicar el algoritmo derivado con la metodología propuesta a la serie temporal de datos LTDR, en los periodos 1984-1998 y 2001-2011, agrupados por décadas (ochenta, noventa y primera década del siglo XXI, aproximadamente).

Se ha evaluado la exactitud de los mapas anuales de áreas quemadas obtenidos con relación a los datos de referencia de las bases de datos CFSNFD



**Figura 4.** Arquitectura básica de la herramienta SDCCV desarrollada para la automatización de la metodología de detección de cambios en series temporales de imágenes de satélite.

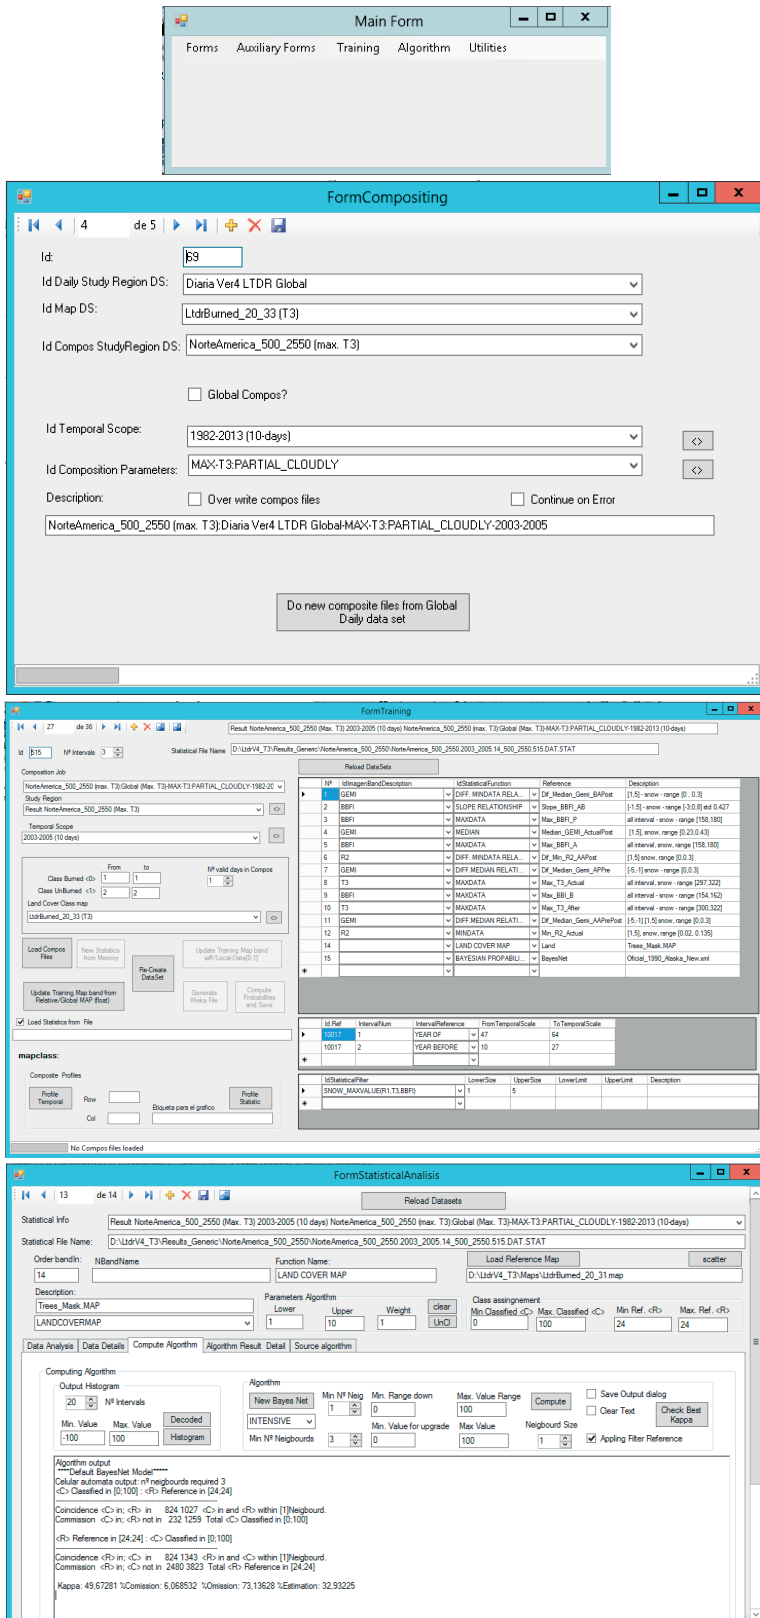
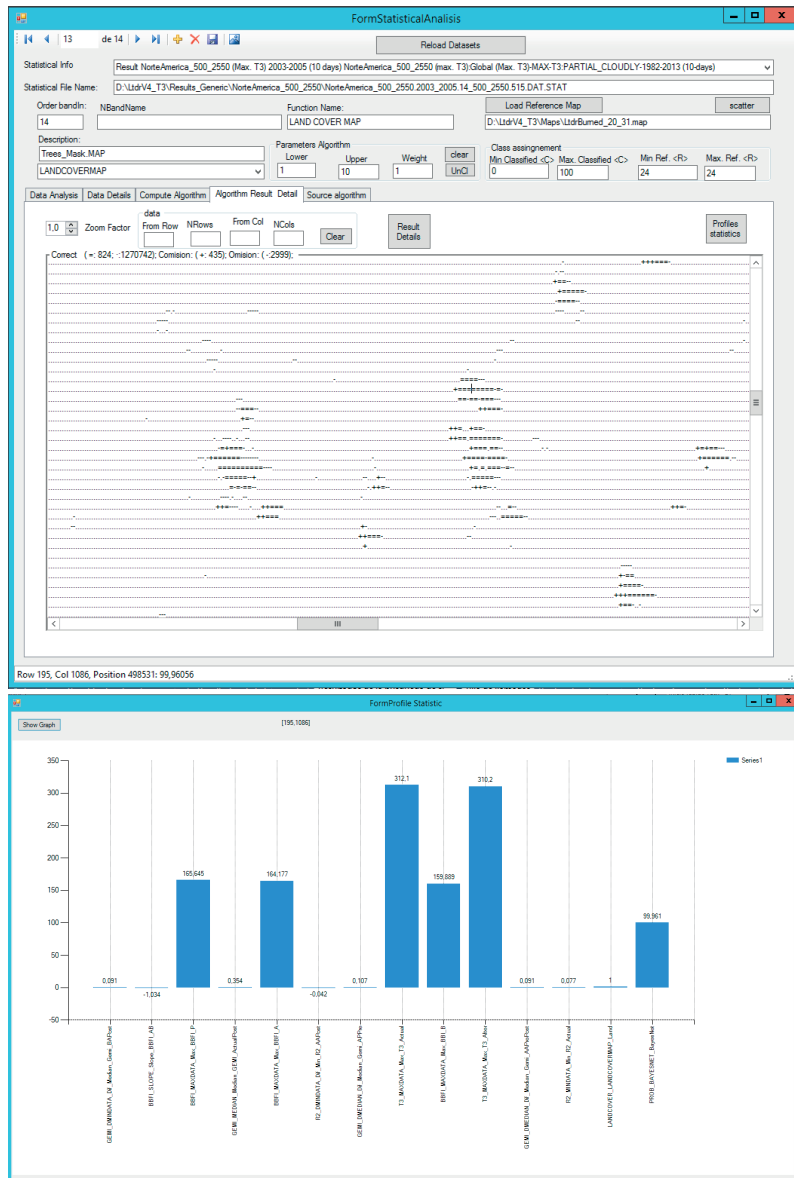


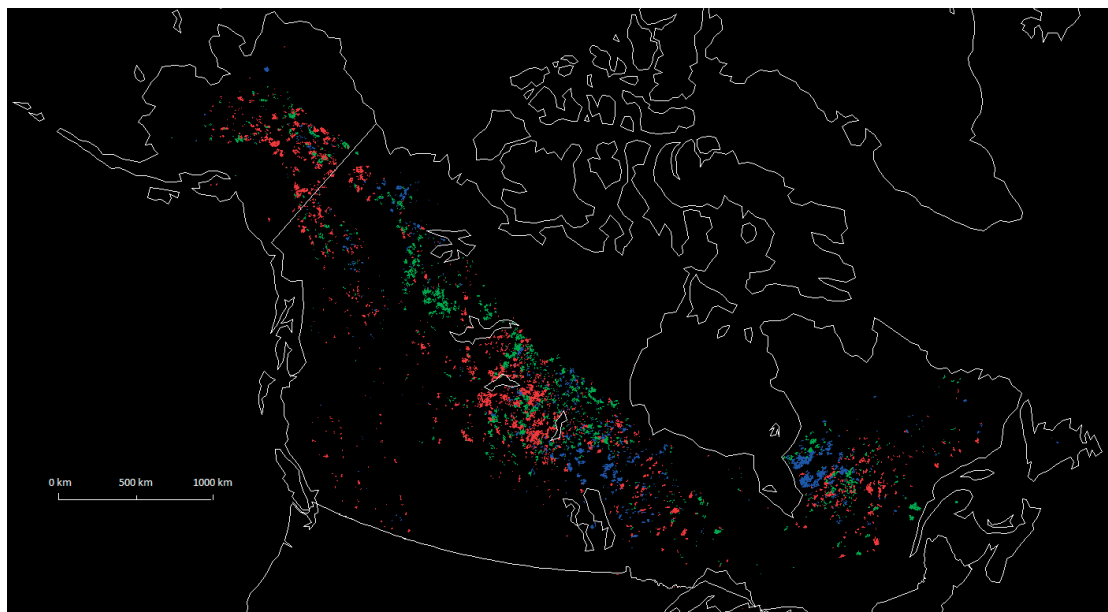
Figura 5 (Continúa en página siguiente).



**Figura 5** (Continúa de la página anterior). Ejemplos de formularios de la herramienta SDCCV desarrollada para la automatización de la metodología de detección de cambios en series temporales de imágenes de satélite, al aplicarla a la detección de área quemada.

y AFS. Se ha llevado a cabo un análisis de regresión lineal de las estimaciones de área quemada en celdas de 40 km×40 km (usando proyección LCC) de los mapas generados frente a los mapas de referencia. Se ha calculado la matriz de error asociada (Congalton, 1991) y se han obteniendo las principales métricas de exactitud derivadas de las mismas (Stehman, 1997). El error medio de omisión obtenido en la estimación del área quemada

en el periodo total considerado está en torno al 50% y el error medio de comisión en torno al 15% (Tabla 5), con ligeras oscilaciones a lo largo de la serie temporal. El valor del error de omisión puede parecer algo elevado, pero entra dentro de lo esperado teniendo en cuenta la baja resolución espacial de las imágenes consideradas que dificulta la detección de pequeñas áreas quemadas.



**Figura 6.** Mapas de área quemada (1984-2011) de la región boreal de Norteamérica obtenidos a partir del conjunto de datos LTDR. En color azul se han representado las áreas quemadas en la década de los 80 (1984-1989), en verde las de la década de los 90 (1990-1998) y en rojo las quemadas a partir del año 2001 (2001-2011). Para la interpretación de los colores consultar edición digital, <http://dx.doi.org/10.4995/raet.2014.2280>.

En un análisis exhaustivo, fuego por fuego para grandes incendios (>100000 ha) y con la verificación mediante imágenes Landsat-TM post-fuego, se ha constatado que una parte importante de los errores de comisión corresponde a errores de

medición en los polígonos de referencia, así como la no consideración de áreas adyacentes o de la fragmentación interna de las áreas quemadas, pudiendo quedar reducido el error medio de comisión real para los grandes fuegos a menos de la

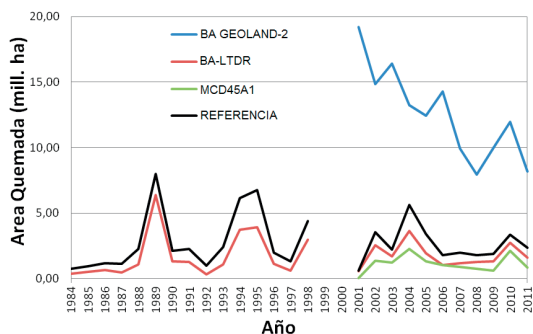
**Tabla 5.** Evaluación de la exactitud de los resultados obtenidos en este trabajo con respecto a los datos de referencia (bases de datos CFSNFD y AFS). Se presenta por un lado, la pendiente de la regresión lineal del porcentaje de píxeles quemados del producto BA-LTDR en celdas de 40 km x 40 km por año para la región boreal de Norte América con respecto a los correspondientes de las referencias, y su coeficiente de determinación ( $R^2$ ), y por otro lado, los errores de comisión y omisión encontrados.

Región Boreal de Norte América (UL: 70°N,-168,5°E; LR: 45°N,-53°E)									
Años	Pendiente	$R^2$	% Error de Comisión	% Error de Omisión	Años	Pendiente	$R^2$	% Error de Comisión	% Error de Omisión
1984	0,39	0,42	0,29	0,66	1999				
1985	0,56	0,56	0,26	0,59	2000				
1986	0,70	0,84	0,11	0,51	2001	0,62	0,50	0,44	0,48
1987	0,54	0,63	0,15	0,64	2002	0,75	0,76	0,18	0,42
1988	0,42	0,63	0,21	0,66	2003	0,77	0,73	0,24	0,42
1989	0,73	0,80	0,15	0,32	2004	0,67	0,86	0,08	0,40
1990	0,69	0,79	0,12	0,47	2005	0,46	0,54	0,25	0,58
1991	0,67	0,68	0,17	0,54	2006	0,31	0,33	0,36	0,64
1992	0,35	0,59	0,15	0,71	2007	0,56	0,66	0,16	0,50
1993	0,41	0,64	0,10	0,59	2008	0,75	0,81	0,13	0,38
1994	0,63	0,83	0,09	0,46	2009	0,79	0,84	0,13	0,40
1995	0,60	0,84	0,09	0,48	2010	0,92	0,86	0,17	0,32
1996	0,61	0,63	0,25	0,58	2011	0,79	0,86	0,11	0,40
1997	0,36	0,53	0,37	0,70					
1998	0,67	0,78	0,16	0,43	Resumen	0,62	0,76	0,14	0,49

mitad (en torno al 6%). En el caso de los errores de omisión, también se han encontrado algunas inconsistencias, ya que hay áreas quemadas de referencia que no son detectadas en el producto BA-LTDR pero que tampoco se observan en las imágenes Landsat-TM; hay también algunas otras áreas que o bien no se ajustan al polígono de referencia o bien mantienen una persistencia de la señal muy débil en años posteriores. El error medio de omisión para los grandes fuegos respecto a las imágenes Landsat-TM teniendo en cuenta estas correcciones se podría reducir a un 35%, aproximadamente.

Por otro lado, se han comparado los resultados obtenidos por el clasificador bayesiano para imágenes LTDR en la región de bosque boreal de Norteamérica con otros productos de área quemada disponibles de mayor resolución espacial (500 m y 1 km), dentro de los límites espacio/temporales de los mismos, ya que algunos de estos productos sólo están disponibles a partir del año 2000 y no cubren el periodo total de la serie LTDR (Moreno Ruiz *et al.*, 2012; Moreno Ruiz *et al.*, 2014; Nuñez-Casillas *et al.*, 2013), y otros están limitados a una región limitada espacialmente (Chuvieco *et al.*, 2008).

En la Figura 7 se comparan de los resultados generados por el algoritmo utilizando imágenes LTDR, en términos de área quemada total anual para el periodo 1984-2011 (exceptuando los años 1999 y 2000), con dos productos oficiales de área quemadas: el producto MCD45A1, derivado a partir del sensor MODIS, con 500 m de resolución espacial



**Figura 7.** Estimaciones anuales de área quemada en el bosque boreal de Norteamérica en el periodo 1984-2011, obtenidas de los productos de área quemada MCD45A1 (500 m de resolución espacial), BA GEOLAND-2 (1 km) y BA-LTDR (5 km), y las registradas en la bases de datos de referencia.

(Roy *et al.*, 2008; Roy *et al.*, 2005), y el producto BA GEOLAND-2 derivado a partir del sensor VEGETATION con 1 km de resolución espacial (Tansey *et al.*, 2012). Los productos MCD45A1 y BA-LTDR presentan un buen ajuste al perfil temporal de área quemada de los datos de referencia, pero con una sub-estimación del área quemada anual que es menor en el producto BA-LTDR que en MCD45A1. El producto BA GEOLAND-2 no se ajusta al patrón temporal de área quemada y presenta una fuerte sobre-estimación del área quemada anual.

En la Tabla 6 se comparan los errores de comisión y omisión solamente en el periodo 2001-2011 para los tres productos considerados. Nuevamente se

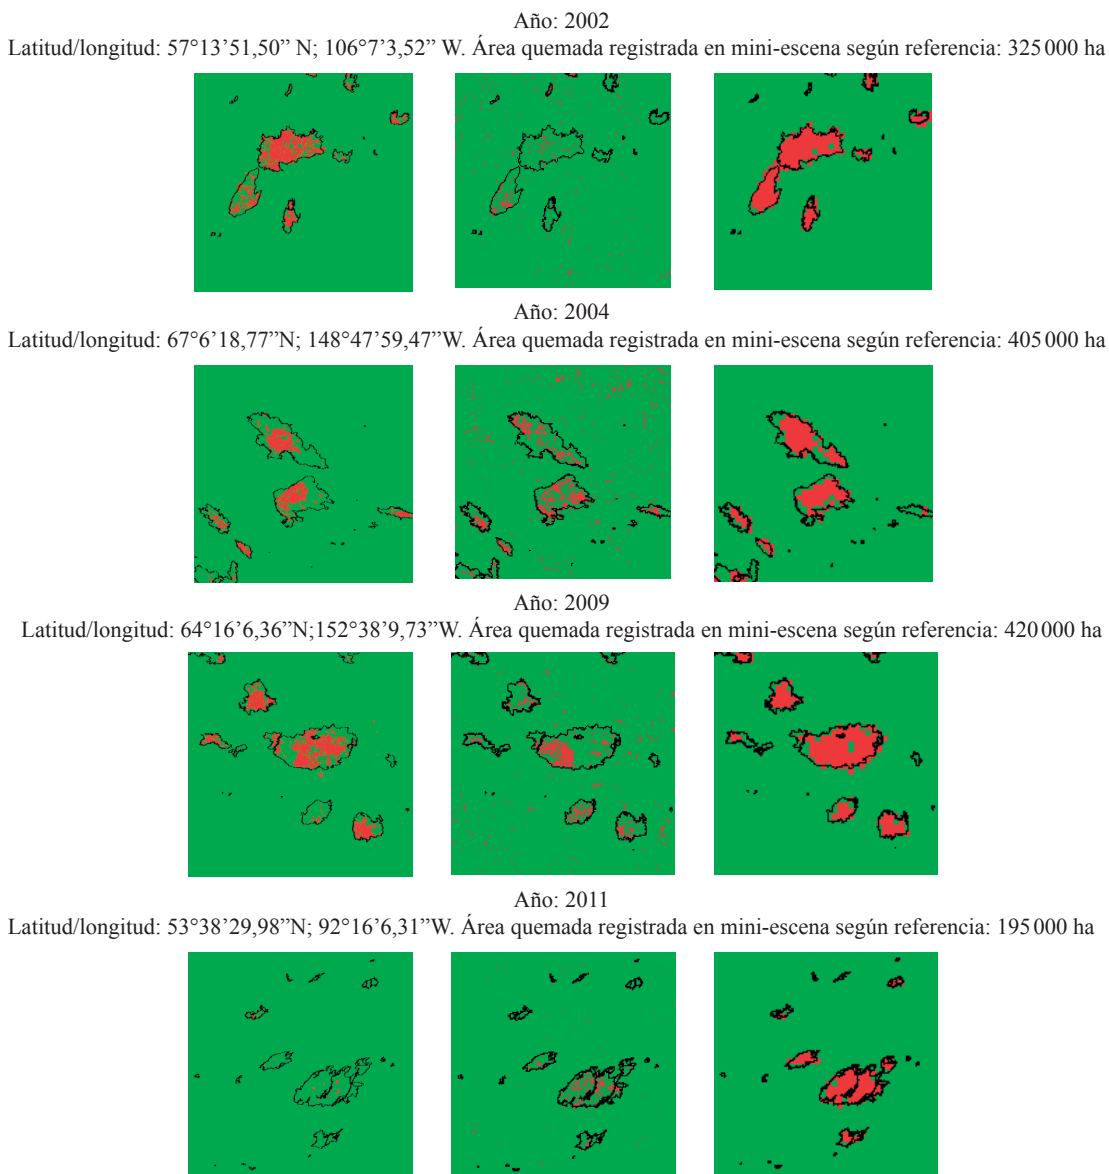
**Tabla 6.** Errores anuales de comisión y omisión para la región boreal de Norte América para los productos de área quemada MCD45A1, BA GEOLAND-2 y BA-LTDR.

Año	MCD45A1		BA GEOLAND-2		BA-LTDR	
	Error de Comisión	Error de Omisión	Error de Comisión	Error de Omisión	Error de Comisión	Error de Omisión
2001	0,59	0,97	0,98	0,53	0,44	0,48
2002	0,19	0,69	0,93	0,71	0,18	0,42
2003	0,20	0,57	0,95	0,65	0,24	0,42
2004	0,09	0,63	0,86	0,68	0,08	0,40
2005	0,13	0,66	0,94	0,77	0,25	0,58
2006	0,29	0,59	0,96	0,71	0,36	0,64
2007	0,16	0,63	0,93	0,63	0,16	0,50
2008	0,10	0,61	0,94	0,74	0,13	0,38
2009	0,18	0,74	0,94	0,69	0,13	0,40
2010	0,38	0,61	0,92	0,70	0,17	0,32
2011	0,07	0,68	0,94	0,78	0,11	0,40
Total	0,19	0,65	0,94	0,70	0,18	0,44

observan unos mejores resultados para el producto generado con la metodología propuesta para el conjunto de datos LTDR, con errores totales de comisión y de omisión de 0,18 y 0,44, respectivamente, frente a los datos del producto oficial de área quemada MCD45A1, con comisión de 0,19 y omisión de 0,65, ligeramente peores pese a tener una mayor

resolución espacial (500 m). Los resultados del producto BA GEOLAND-2, con 1 km de resolución espacial, son francamente malos, con un error de comisión de 0,94 y un error de omisión de 0,70.

Finalmente, en la Figura 8 se presentan cuatro ejemplos de áreas quemadas detectadas por los



**Figura 8.** Cuatro ejemplos de detección de grandes incendios (>100 000 ha) para los productos de área quemada considerados (de izquierda a derecha): MCD45A1 (500 m de resolución espacial), BA GEOLAND-2 (1 km) y BA-LTDR (5 km). De cada mini-imagen se ha especificado el año y las coordenadas geográficas (latitud/longitud) de la esquina superior izquierda. El color rojo indica el área quemada detectada, y la línea negra delimita el perímetro de las áreas quemadas registradas por los datos de referencia sobre cada sub-escena. Para la interpretación de los colores consultar edición digital, <http://dx.doi.org/10.4995/raet.2014.2280>.



productos MCD45A1, BA GEOLAND-2 y BA-LTDR. Estos ejemplos han sido seleccionados porque registraron grandes incendios (>100 000 ha) según los datos de referencia. Nuevamente se observa la mayor exactitud espacial del producto BA-LTDR frente al producto MCD45A1, el cual presenta una mayor infraestimación, y frente al producto BA GEOLAND-2, que presenta mayores errores tanto de omisión como de comisión (falsas detecciones de área quemada).

#### 4. Conclusiones

Se ha propuesto una metodología genérica para la detección de cambios de la cubierta vegetal en series temporales de imágenes de satélite diarias. Se ha diseñado un software ex profeso que permite implementar dicha metodología. Se ha aplicado de forma efectiva al conjunto diario de datos LTDR (~5 km de resolución espacial) para la obtención de mapas de áreas quemadas en bosques boreales de Norte América en el periodo 1984-2011. El algoritmo basado en redes bayesianas que se ha generado a partir de esta metodología obtiene resultados muy superiores a los obtenidos por los productos oficiales de área quemada MCD45A1 y BA GEOLAND-2, tanto en estimación de área quemada como en exactitud espacio-temporal de las estimaciones, siendo su intervalo temporal de aplicación mayor que el de los otros dos productos que sólo están disponibles a partir del año 2000.

#### Agradecimientos

Este trabajo está financiado por el Ministerio de Economía y Competitividad de España a través del proyecto CGL2013-48202-C2-2-R. Un especial agradecimiento a las Agencias y Servicios de procesamiento de datos de satélite de NASA y NOAA, las cuales nos han suministrado la mayor parte de las imágenes empleadas en este trabajo (LANDSAT, MODIS, LAC and LTDR). Finalmente agradecer a los revisores anónimos por sus comentarios constructivos, los cuales fueron especialmente tenidos en consideración.

#### Referencias

- Al-Rawi, K.R., Casanova, J.L., Calle, A. 2001. Burned area mapping system and fire detection system, based on neural networks and NOAA-AVHRR imagery. *International Journal of Remote Sensing*, 22(10), 2015-2032. <http://dx.doi.org/10.1080/01431160117531>
- Barbosa, P.M., Pereira, J.M.C., Grégoire, J.M. 1998. Compositing Criteria for Burned Area Assessment Using Multitemporal Low Resolution Satellite Data. *Remote Sensing of Environment*, 65(1), 38-49. [http://dx.doi.org/10.1016/S0034-4257\(98\)00016-9](http://dx.doi.org/10.1016/S0034-4257(98)00016-9)
- Bayes, T. 1763. An essay towards solving a problem in the doctrine of chances. *Philosophical Transactions of the Royal Society of London*, 53, 370-418. <http://dx.doi.org/10.1098/rstl.1763.0053>
- Burks, A.W. 1970. *Essays on cellular automata*. University of Illinois Press, Urbana, Illinois.
- Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46. [http://dx.doi.org/10.1016/0034-4257\(91\)90048-B](http://dx.doi.org/10.1016/0034-4257(91)90048-B)
- Crosetto, M., Moreno Ruiz, J.A., Crippa, B. 2001. Uncertainty propagation in models driven by remotely sensed data. *Remote Sensing of Environment*, 76(3), 373-385. [http://dx.doi.org/10.1016/S0034-4257\(01\)00184-5](http://dx.doi.org/10.1016/S0034-4257(01)00184-5)
- Chuvieco, E., Englefield, P., Trishchenko, A.P., Luo, Y. 2008. Generation of long time series of burn area maps of the boreal forest from NOAA-AVHRR composite data. *Remote Sensing of Environment*, 112(5), 2381-2396. <http://dx.doi.org/10.1016/j.rse.2007.11.007>
- Chuvieco, E., Ventura, G., Martín, M.P., Gómez, I. 2005. Assessment of multitemporal compositing techniques of MODIS and AVHRR images for burned land mapping. *Remote Sensing of Environment*, 94(4), 450-462. <http://dx.doi.org/10.1016/j.rse.2004.11.006>
- Foody, G.M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201. [http://dx.doi.org/10.1016/S0034-4257\(01\)00295-4](http://dx.doi.org/10.1016/S0034-4257(01)00295-4)
- García Lázaro, J.R., Moreno Ruiz, J.A., Arbeló, M. 2013. Effect of spatial resolution on the accuracy of satellite based fire scar detection in the north-west of the Iberian Peninsula. *International Journal of Remote Sensing*, 34(13), 4736-4753. <http://dx.doi.org/10.1080/01431161.2013.781290>
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I.H. 2009. The WEKA Data Mining Software: An Update. *SIGKDD Explorations*, 11(1), 10-18. <http://dx.doi.org/10.1145/1656274.1656278>

- Moreno-Ruiz, J.A., Riaño, D., García-Lazaro, J.R., Ustin, S.L. 2009. Intercomparison of AVHRR PAL and LTDR version 2 long-term data sets for Africa from 1982 to 2000 and its impact on mapping burned area. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 738-742. <http://dx.doi.org/10.1109/LGRS.2009.2024436>
- Moreno Ruiz, J.A., Riaño, D., Arbelo, M., French, N.H.F., Ustin, S.L., Whiting, M.L. 2012. Burned area mapping time series in Canada (1984-1999) from NOAA-AVHRR LTDR: A comparison with other remote sensing products and fire perimeters. *Remote Sensing of Environment*, 117, 407-414. <http://dx.doi.org/10.1016/j.rse.2011.10.017>
- Moreno Ruiz, J.A., García Lázaro, J.R., del Águila Cano, I., Hernández Leal, P. 2014. Burned area mapping in the North American boreal forest using terra-MODIS LTDR (2001-2011): A comparison with the MCD45A1, MCD64A1 and BA GEOLAND-2 products. *Remote Sensing*, 6(1), 815-840. <http://dx.doi.org/10.3390/rs6010815>
- Núñez-Casillas, L., García Lázaro, J.R., Moreno-Ruiz, J.A., Arbelo, M. 2013. A Comparative Analysis of Burned Area Datasets in Canadian Boreal Forest in 2000. *The Scientific World Journal*, 2013: 13. <http://dx.doi.org/10.1155/2013/289056>
- Pedely, J., Devadiga, S., Masuoka, E., Brown, M., Pinzon, J., Tucker, C., Pinheiro, A., 2007. Generating a long-term land data record from the AVHRR and MODIS instruments. En: *Geoscience and Remote Sensing Symposium (IGARSS)*. Barcelona (España), 23-28, julio. pp. 1021-1025.
- Pinty, B., Verstraete, M.M. 1992. GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetatio*, 101(1), 15-20. <http://dx.doi.org/10.1007/BF00031911>
- Riaño, D., Moreno Ruiz, J.A., Isidoro, D., Ustin, S.L. 2007. Global spatial patterns and temporal trends of burned area between 1981 and 2000 using NOAA-NASA Pathfinder. *Global Change Biology*, 13(1), 40-50. <http://dx.doi.org/10.1111/j.1365-2486.2006.01268.x>
- Roy, D.P., Boschetti, L., Justice, C.O., Ju, J. 2008. The collection 5 MODIS burned area product - Global evaluation by comparison with the MODIS active fire product. *Remote Sensing of Environment*, 112(9), 3690-3707. <http://dx.doi.org/10.1016/j.rse.2008.05.013>
- Roy, D.P., Jin, Y., Lewis, P.E., Justice, C.O. 2005. Prototyping a global algorithm for systematic fire-affected area mapping using MODIS time series data. *Remote Sensing of Environment*, 97(2), 137-162. <http://dx.doi.org/10.1016/j.rse.2005.04.007>
- Stehman, S.V. 1997. Estimating standard errors of accuracy assessment statistics under cluster sampling. *Remote Sensing of Environment*, 60(3), 258-269. [http://dx.doi.org/10.1016/S0034-4257\(96\)00176-9](http://dx.doi.org/10.1016/S0034-4257(96)00176-9)
- Tansey, K., Bradley, A., Smets, B., van Best, C., Lacaze, R. 2012. The Geoland2 BioPar burned area product. En: *EGU General Assembly Conference Abstracts*. Viena (Austria), 22-27, abril, pp. 4727.
- Zhan, X., Sohlberg, R.A., Townshend, J.R.G., DiMiceli, C., Carroll, M.L., Eastman, J.C., Hansen, M.C., DeFries, R.S. 2002. Detection of land cover changes using MODIS 250 m data. *Remote Sensing of Environment*, 83(1-2), 336-350. [http://dx.doi.org/10.1016/S0034-4257\(02\)00081-0](http://dx.doi.org/10.1016/S0034-4257(02)00081-0)