



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN GEOGRAFÍA

Identificación semi-automática de cambios abruptos en series de tiempo Landsat para determinar zonas afectadas por incendios en La Primavera, Jalisco.

TESIS

QUE PARA OPTAR POR EL GRADO DE:

MAESTRA EN GEOGRAFÍA

PRESENTA:

Gabriela Villamil Cortez

DIRECTOR DE TESIS

Dr. Inder Rafael Tecuapetla Gómez

CONACYT - CONABIO

Ciudad Universitaria, Cd. Mx. Mayo de 2019



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Dedicada a

Mis padres

AGRADECIMIENTOS

Al posgrado en Geografía por permitirme ser parte de su programa maestría en Geografía y al Consejo Nacional de Ciencia y Tecnología (CONACYT) por haberme otorgado la beca para realizar los estudios de maestría.

En especial a mi asesor el Dr. Inder Rafael Tecuapetla Gómez por todo su apoyo, confianza y dedicación para culminar la tesis. Por sus consejos académicos y valiosas aportaciones para mejorar la tesis. También por compartir conmigo su amplio conocimiento en el lenguaje de programación R y código del mismo para la aplicación del método.

A mis revisores Dr. Rainer Ressler, Dra. Lilia Manzo, Dra. Leticia Gómez y al Dr. Stephane Couturier por sus comentarios y recomendaciones para mejorar la tesis.

Al Dr. René Colditz por el apoyo que me brindó desde el primer día en la CONABIO y por facilitarme código del lenguaje de programación IDL para el procesamiento de datos Landsat.

A la CONABIO y a la Dra. Isabel Cruz por el apoyo en el desarrollo de la tesis y por proporcionarme datos de áreas quemadas del área de estudio utilizados para la validación del trabajo.

A las personas más importantes en mi vida, mi familia; Alberto, Josefina, Car, Fredy y Vin quienes, con su cariño y apoyo, han sido el impulso para seguir adelante incentivándome a que cada día de mi mejor esfuerzo. En especial a la mujer que más admiro, mi madre (Josefina) por sus consejos, amor incondicional y por todo el esfuerzo que ha hecho para que pueda cumplir mis metas.

A Eliseo por su amor y paciencia. Por estar ahí siempre apoyándome en todo y hacer mis días más divertidos y felices.

Y a mis compañeros Moises, Cynthia, Bere, Gloria y Carlos por compartirme sus conocimientos y material bibliográfico, además de brindarme su amistad.

CONTENIDO

RESUMEN	1
ABSTRACT	2
I. INTRODUCCIÓN.....	3
1.1 JUSTIFICACIÓN.....	4
1.2 HIPÓTESIS	5
1.3 OBJETIVOS	5
1.3.1 Objetivo General	5
1.3.2 Objetivos específicos.....	5
II. ÁREA DE ESTUDIO Y DATOS	6
2.1 ÁREA DE ESTUDIO.....	6
2.2 DATOS.....	9
2.2.1 Datos de Referencia	9
2.2.2 Especificaciones técnicas del satélite Landsat-7 ETM+.....	10
III. MÉTODO.....	12
3.1 PRE-PROCESAMIENTO DE LAS IMÁGENES	12
3.1.1 Recorte del área de estudio	13
3.1.2 Generación y aplicación de máscaras	14
3.1.3 Índices espectrales (series de tiempo NDVI-NBR)	15
3.1.3.1 Cálculo de índices espectrales	16
i. Normalized Difference Vegetation Index (NDVI)	17
ii. Normalized Burn Ratio (NBR).....	18
iii. Differenced Normalized Burn Ratio (dNBR)	19
3.1.4 Rellenado de datos.....	20
3.1.5 Apilamiento de imágenes.....	22
3.2 BREAKS FOR ADDITIVE SEASONAL AND TREND (BFAST).....	23
3.2.1 Descomposición del modelo aditivo de tendencia y temporalidad	24
3.2.2 Detección de cambios abruptos en series de tiempo NDVI.....	25
3.3 ASOCIACIÓN DE LOS CAMBIOS ABRUPTOS CON ÁREAS QUEMADAS.....	27
3.4 CLASIFICACIÓN DEL CAMBIO.....	28

3.5 PRUEBAS DE SIMULACIÓN	28
3.6 VALIDACIÓN	30
3.6.1 Evaluación de la exactitud.....	30
IV. RESULTADOS	33
4.1 DISPONIBILIDAD DE DATOS PARA EL ÁREA DE ESTUDIO	33
4.1.1 Áreas quemadas registradas en el área de estudio a través de datos de campo y derivadas por imágenes de satélite.....	34
4.2 EJEMPLOS DE ESCENAS CON DIFERENTES PORCENTAJES DE DATOS FALTANTES Y RELLENADAS.....	35
4.3 PRUEBAS DE SIMULACIÓN EN SERIES DE TIEMPO NDVI.....	37
4.3.1 Identificación de un punto de cambio	37
4.3.2 Identificación de dos puntos de cambio	41
4.4 APLICACIÓN ESPACIAL EN SERIES DE TIEMPO LANDSAT-7 (NDVI)	44
4.5 PROXY- SEVERIDAD DE LAS ÁREAS QUEMADAS DETECTADAS	52
4.6 VALIDACIÓN	69
4.6.1 Evaluación de la exactitud del área quemada del año 2012	69
4.6.1.1 <i>Alternativas para remover aparente bandeo en el mapa de proxy-severidad del área quemada del año 2012.....</i>	71
4.6.1.2 <i>Comparación de las exactitudes de los diferentes métodos usados para remover aparente bandeo en el mapa de proxy-severidad del año 2012</i>	73
4.6.2 Evaluación de la exactitud del área quemada para el año 2012 utilizando grupos de píxeles con diferente calidad.....	79
V. DISCUSIÓN.....	86
VI. CONCLUSIONES	89
REFERENCIAS.....	91
ANEXOS	96

ÍNDICE DE FIGURAS

Figura 1. Localización Geográfica del área de estudio.....	6
Figura 2. Mapa de uso de suelo y vegetación del área de estudio.....	8
Figura 3. Fallo del sistema SLC en las imágenes Landsat-7.....	11
Figura 4. Diagrama de las etapas para la detección de cambios abruptos ligados a incendios.....	13
Figura 5. Recorte del área de estudio para las 230 imágenes Landsat-7 descargadas.....	14
Figura 6. Aplicación de máscaras.....	15
Figura 7. Respuesta espectral; vegetación no quemada vs áreas quemadas.....	16
Figura 8. Rellenado de datos faltantes (NA's).....	21
Figura 9. Representación de los cubos de NDVI y NBR.....	22
Figura 10. Descomposición de la serie de tiempo con BFAST.....	23
Figura 11. Total de imágenes Landsat-7 disponibles para la escena 29/46 por año y mes.....	33
Figura 12. Histograma del porcentaje de datos faltantes (NA's) en las imágenes Landsat-7 para el APFFLP.....	34
Figura 13. Áreas quemadas registradas en el área de estudio.....	35
Figura 14. Rellenado de datos faltantes del APFFLP.....	36
Figura 15. Series de tiempo NDVI simuladas en la componente de tendencia.....	37
Figura 16. Gráfica del porcentaje de cobertura total de identificación de un punto de cambio (σ cambia).....	38
Figura 17. Gráfica del porcentaje de cobertura total de identificación de un punto de cambio (h cambia).....	39
Figura 18. Gráfica del porcentaje total de un punto de cambio correctamente identificado con diferentes valores de σ (caso 1).....	40
Figura 19. Gráfica del porcentaje total de un punto de cambio correctamente identificado con diferentes valores de h (caso 2).....	40
Figura 20. Gráfica de la precisión de BFAST para estimar el número de cambios abruptos usando el MSE.....	41
Figura 21. Gráfica del porcentaje total de dos puntos de cambio correctamente identificados con $h=0.15$	41
Figura 22. Gráfica del porcentaje total de dos puntos de cambio correctamente identificados con $h=0.23$	42
Figura 23. Gráfica del porcentaje total de sobrestimación de puntos de cambio con $h=0.15$	42
Figura 24. Gráfica del porcentaje total de subestimación de puntos de cambio con $h=0.15$	43
Figura 25. Gráfica del porcentaje total de subestimación de puntos de cambio con $h=0.23$	43
Figura 26. Mapa de cambios y magnitud del cambio.....	49
Figura 27. Cambios detectados en la componente de tendencia de la serie de tiempo NDVI de un pixel específico del área de estudio.....	50

Figura 28.Detección del punto de cambio del 2013 en series de tiempo NDVI con 30% de NA's	50
Figura 29.Tendencia estimada de la serie de tiempo NDVI .Pixel de áreas quemadas en 2005 y 2013.....	51
Figura 30.Tendencia estimada de la serie de tiempo NDVI. Pixel de áreas quemadas en 2005 y 2012.....	52
Figura 31.Mapas de proxy-severidad de la quema basados en Δ NBR 2005 y 2006, $h=0.15$	53
Figura 32.Mapas de proxy-severidad de la quema basados en Δ NBR 2007 y 2008, $h=0.15$	54
Figura 33.Mapas de proxy-severidad de la quema basados en Δ NBR 2009 y 2010, $h=0.15$	55
Figura 34.Mapas de proxy-severidad de la quema basados en Δ NBR 2011 y 2012, $h=0.15$	56
Figura 35.Mapas de proxy-severidad de la quema basados en Δ NBR 2013 y 2014, $h=0.15$	57
Figura 36.Mapas de proxy-severidad de la quema basados en Δ NBR 2006 y 2007, $h=0.23$	58
Figura 37.Mapas de proxy-severidad de la quema basados en Δ NBR 2008 y 2009, $h=0.23$	59
Figura 38.Mapas de proxy-severidad de la quema basados en Δ NBR 2010 y 2011, $h=0.23$	60
Figura 39.Mapas de proxy-severidad de la quema basados en Δ NBR 2012 y 2013, $h=0.23$	61
Figura 40.Gráfica del total aproximado de hectáreas quemadas detectadas con cada valor de h	64
Figura 41.Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad baja	65
Figura 42.Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad media	65
Figura 43.Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad alta	66
Figura 44.Mapa del total de áreas quemadas detectadas y nivel de severidad de las quemas en el periodo 2003-2016 basados en Δ NBR para el valor de $h=0.15$	67
Figura 45.Mapa del total de áreas quemadas detectadas y nivel de severidad de las quemas en el periodo 2003-2016 basados en Δ NBR para el valor de $h=0.23$	68
Figura 46.Evaluación de la exactitud del área quemada de 2012, $h=0.15$	69
Figura 47.Evaluación de la exactitud del área quemada de 2012, $h=0.23$	70
Figura 48.Estrategia A para remover aparente bandeo del mapa de proxy- severidad del 2012.	71
Figura 49.Estrategia B para remover aparente bandeo del mapa de proxy- severidad del 2012.	72
Figura 50.Estrategia C para remover aparente bandeo del mapa de proxy- severidad del 2012, utilizando $h=0.15$	73
Figura 51.Gráfica comparativa de la exactitud global de las diferentes estrategias utilizadas vs el método 23_A. I, 1_D. I para la quema del 2012	74
Figura 52.Mapa del porcentaje de datos faltantes (NA's) por pixel del área de estudio	80
Figura 53.Máscara utilizada para la evaluación de exactitud del área quemada de 2012.....	81
Figura 54.Aumento de la exactitud global del área quemada de 2012 utilizando la máscara con los dos grupos de pixeles	85
Figura 55.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de pixeles 2 (método 23_A. I, 1_D. I)	96

Figura 56.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (método 23_A. I, 1_D. I)	96
Figura 57.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 2 (Estrategia B)	97
Figura 58.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (Estrategia B)	97
Figura 59.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 2 (Estrategia C)	98
Figura 60.Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (Estrategia C)	98

ÍNDICE DE TABLAS

Tabla 1. Cobertura por municipio del APFFLP.....	7
Tabla 2. Características del satélite Landsat-7 ETM+.....	10
Tabla 3. Niveles de severidad de la quema.....	20
Tabla 4. Parámetros de la simulación de un punto de cambio de la serie de tiempo NDVI	29
Tabla 5. Parámetros de la simulación de dos puntos de cambio de la serie temporal NDVI	29
Tabla 6. Ejemplo de una matriz de confusión o matriz de error	31
Tabla 7. Cambios abruptos detectados por año	45
Tabla 8. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (método 23_A. I, 1_D. I, h=0.15)	75
Tabla 9. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (método 23_A. I, 1_D. I, h=0.23)	76
Tabla 10. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia A, h=0.15)	77
Tabla 11. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia A, h=0.23)	77
Tabla 12. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia B, h=0.15)	78
Tabla 13. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia B, h=0.23)	78
Tabla 14. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia C, h=0.15)	79
Tabla 15. Porcentaje de datos faltantes por pixel de la máscara utilizada para la evaluación de exactitud del área quemada de 2012	82
Tabla 16. Matriz de confusión basada en la figura 55 (método 23_A. I, 1_D. I, h=0.15) usando la máscara del grupo 2	82
Tabla 17. Matriz de confusión basada en la figura 56 (método 23_A. I, 1_D. I, h=0.15) usando la máscara del grupo 1	83
Tabla 18. Matriz de confusión basada en la figura 57 (Estrategia B, h=0.23) usando la máscara del grupo 2	83
Tabla 19. Matriz de confusión basada en la figura 58 (Estrategia B, h=0.23) usando la máscara del grupo 1	83
Tabla 20. Matriz de confusión basada en la figura 59 (Estrategia C, h=0.15) usando la máscara del grupo 2	84
Tabla 21. Matriz de confusión basada en la figura 60 (Estrategia C, h=0.15) usando la máscara del grupo 1	84

RESUMEN

El presente estudio provee una metodología para determinar áreas quemadas de manera automática. El método implementado se basa en la aplicación de BFAST (Breaks For Additive Seasonal and Trend) a series de tiempo del Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en inglés) y el Cociente Normalizado de Área Quemada (NBR por sus siglas en inglés) derivadas de imágenes satelitales Landsat-7 para detectar cambios abruptos en la vegetación y la utilización de la diferencia del NBR (dNBR) para ligar dichos cambios abruptos con áreas quemadas en el área de Protección de Flora y Fauna La Primavera, Jalisco.

Se aplicó BFAST a series de tiempo sintéticas de NDVI de 16 días con cantidades variables de datos faltantes (NA's), ruido y que contenían perturbaciones o cambios abruptos. En general, estos estudios de simulación revelaron que la precisión de BFAST para estimar puntos de cambio decrece en función a la cantidad de NA's en la serie de tiempo.

Por otra parte, la aplicación del método a la serie de tiempo NDVI Landsat-7 de 2003 a 2016 para el área de estudio, demostró que se pueden usar los cambios abruptos detectados por BFAST para relacionarlos con áreas quemadas. En un primer paso, se estimaron los cambios abruptos por pixel en la serie temporal NDVI. Luego, se calculó una colección de índices de severidad de la quema (dNDVI y dNBR) basadas en las estimaciones obtenidas en el primer paso. Los mapas finales de severidad de las áreas quemadas se basan tanto en el cambio abrupto estimado (en la escala anual) como en los índices correspondientes. Finalmente se evaluó estadísticamente la exactitud del mapa del área quemada del 2012 (uno de los incendios más grandes que afectaron al área) el cual presentó una exactitud global del 57%, con la posibilidad de aumentar si no existieran NA's. Por lo cual se utilizaron pixeles específicos con cierto porcentaje de NA's para validar el mismo año, los resultados mostraron que la exactitud global de identificación de área quemada tiende a aumentar (por arriba del 70%) cuando se tiene un cubo de información con al menos 40% de NA's. A pesar de esta limitante (datos faltantes) fue posible generar mapas coherentes de las áreas quemadas y su severidad. El enfoque utilizado demostró que BFAST puede ser una buena alternativa para detectar perturbaciones en series de tiempo y para el monitoreo de la recuperación o recrecimiento de la vegetación.

ABSTRACT

The present study provides a methodology to determine areas affected by fires automatically. The method is based on the application of BFAST (Breaks for Additive Seasonal and Trend) to time series of the Normalized Difference Vegetation Index (NDVI) and the Normalized Burned Area Ratio (NBR) derived from Landsat satellite images to detect abrupt changes in vegetation and the use of the NBR difference (dNBR) for linking abrupt changes to fires in the area of Flora and Fauna Protection La Primavera, Jalisco.

We have applied BFAST to 16-day NDVI synthetic time series with varying amounts of missing data (NA's), noise, and containing disturbances or abrupt changes. In general, these simulation studies revealed that the accuracy of BFAST for estimating change points decreases as the number of NA's in the time series increases.

On the other hand, the application of the method to the NDVI Landsat-7-time series from 2003 to 2016 for the study area showed that the abrupt changes detected by BFAST can be used to relate them to abrupt disturbances such as fires. In a first step, we carry out the estimation of abrupt changes per pixel in the NDVI time series. Then, we calculated a collection of burn severity indices (dNDVI and dNBR) based on the estimates obtained in the first step. The final burn severity maps are based on both the abrupt change estimated (on the annual scale) and the corresponding burn severity. Finally, was statistically evaluated the accuracy of the map of the burned area of 2012 (one of the largest fires that affected the area) which showed an overall accuracy of 57%, with increasing possibility if there were no NA's. Therefore, specific pixels with a certain percentage of NA's were used to validate the same year, the results showed that the overall accuracy of identification of burned area tends to increase (above 70%) when you have an information cube with at most 40% of NA's. Despite this limitation (missing data), it was possible to generate coherent maps of the burned areas and their severity. The approach used demonstrated that BFAST can be a good alternative to detect disturbances in time series and to monitor the recovery or regrowth of vegetation.

I. INTRODUCCIÓN

En los últimos años, la interconexión entre la estadística y las técnicas de percepción remota ha contribuido a generar herramientas para aplicaciones ambientales, por ejemplo, para evaluar los cambios ocurridos en diferentes ecosistemas, así como para la generación de cartografía en el estudio de las cubiertas vegetales.

Las limitantes que se presentan a la hora de realizar estudios en ciertas áreas del mundo basados en el uso de datos de satélites con sensores de tipo óptico, son debidas a la falta de datos por diferentes factores como la nubosidad, pues algunas veces no se tienen tantas escenas libres de nubes. Otra de las limitantes, pero específicamente del satélite Landsat-7 es debida a la falla del corrector de línea de escaneo (SLC) en el año 2003 que provocó la pérdida de aproximadamente el 22% de los datos de cada escena (Zhang *et al.*, 2007). Afortunadamente ya existen diferentes métodos para rellenar estos vacíos (Zhu *et al.*, 2012, Chen *et al.*, 2011).

En este estudio se utilizaron imágenes del satélite Landsat-7, ya que actualmente estos productos son gratuitos lo que ha facilitado el acceso a la información, la resolución espacial es adecuada, hay una disponibilidad alta de series de tiempo de dicho satélite y sigue siendo un archivo importante del acervo Landsat, especialmente al final de la vida útil del satélite Landsat-5 TM en 2011. Además de que varios tipos de sensores han sido destacados por su habilidad para correlacionarse con mediciones de severidad en campo, el satélite Landsat ha sido considerado como el más apropiado para esta tarea (Keeley, 2009).

La estimación de los cambios en la vegetación y cobertura de suelo en general a partir de datos de detección remota no es sencilla, ya que, las series de tiempo registran una combinación de cambios fenológicos y de tendencia, además del ruido que se origina a partir de errores geométricos remanentes, dispersión atmosférica y efectos de nubes (Verbesselt *et al.*, 2010). Sin embargo, los sensores satelitales son adecuados para esta tarea porque proporcionan mediciones repetibles a escala espacial apropiadas para captar los efectos de muchos factores que causan cambios, por ejemplo, incendios, deforestación, urbanización, entre otros (Jin y Sader, 2005).

Para el Área de Protección de Flora y Fauna La Primavera, Jalisco se aplicó un método de estimación de cambios abruptos (BFAST, disponible en R CRAN <http://cran.r-project.org/package=bfast>) a una serie de tiempo Landsat-7 tomada desde 2003 a 2016, con el objetivo de identificar cambios abruptos en vegetación para determinar áreas afectadas por incendios y evaluar su severidad automáticamente. Se proponen una serie de mapas anuales desde los cuales se puede monitorear la severidad de la quema, así como la recuperación o recrecimiento de la vegetación.

1.1 JUSTIFICACIÓN

El Área de Protección de Flora y Fauna La Primavera, Jalisco también conocida como la sierra La Primavera, ubicada al oeste de la ciudad de Guadalajara (tercera ciudad más importante en México), a pesar de ser considerada un área natural protegida presenta problemas debidos al turismo, el aprovechamiento intensivo de los recursos forestales, actividades agropecuarias, además sufre constantemente de incendios forestales siendo los más relevantes los ocurridos en abril de 2005, con 8,400 ha afectadas, y en abril de 2012, que afectó 8,276 ha (Del Castillo, 2006; Delgado, 2012). Estos factores hacen que el APFFLP se convierta en una zona fundamental para desarrollar diferentes investigaciones. Debido a que los cambios que ocurren dentro de este ecosistema son complejos y dinámicos, se aplicó un algoritmo que permite identificar y monitorear a través de series de tiempo dichos cambios, de manera que se pueda evaluar el daño y el recrecimiento o recuperación de la vegetación.

Desde el punto de vista geográfico, el estudio de cambios en la vegetación resulta de vital importancia, ya que estos ocurren en el espacio geográfico en los que funciona todo un sistema y por tanto se desencadenan problemáticas que tiene impactos significativos desde el punto de vista social y físico. Si bien es sabido que la regeneración forestal es favorecida después del paso del fuego, la falta de recursos forestales o cambio de ellos debido a incendios severos, además del impacto en la masa arbolada, provoca también pérdida de biodiversidad, la liberación de contaminantes a la atmósfera, cambios en la capacidad de retención y filtración del agua en el suelo e indirectamente favorece a la erosión (Purkis y Klemas 2011), poniendo en riesgo la

estabilidad y los procesos que se desarrollan en el espacio geográfico. Por otra parte, en el APFFLP se encuentran macizos forestales, acuíferos subterráneos y aguas superficiales que en gran parte regulan las condiciones ambientales de Guadalajara y de muchas otras poblaciones aledañas ya que provee de oxígeno y agua. Además, por su configuración topográfica constituye un refugio natural de la fauna silvestre que subsiste en dicha región. De ahí la importancia de realizar este tipo de estudios que ayuden a detectar las perturbaciones que afectan al ecosistema, así como contribuir al aporte de información sobre el tema de estudio.

1.2 HIPÓTESIS

Los cambios abruptos decrecientes en la componente de tendencia de la serie temporal NDVI, permiten detectar perturbaciones (áreas quemadas) mientras que un cambio abrupto creciente puede asociarse con la recuperación o recrecimiento de la vegetación en un ecosistema.

1.3 OBJETIVOS

1.3.1 Objetivo General

Identificación semi-automática de cambios abruptos dentro de series de tiempo Landsat (NDVI) mediante técnicas de percepción remota y el algoritmo BFAST, para determinar zonas afectadas por incendios en la APFFLP, durante el periodo 2003-2016.

1.3.2 Objetivos específicos

- a. Generar y analizar series de tiempo de imágenes satelitales por pixel.
- b. Evaluar la eficacia de BFAST en la identificación de cambios abruptos en la tendencia.
- c. Aplicar BFAST a las series de tiempo del índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en ingles) y el Cociente Normalizado de Área Quemada (NBR por sus siglas en ingles) y ligar los cambios abruptos detectados con áreas quemadas.
- d. Analizar el comportamiento del NDVI y NBR en la identificación de cambios abruptos y las áreas afectadas por incendios.
- e. Evaluar cuantitativamente las clasificaciones obtenidas de severidad de incendios y observar el posible impacto para el monitoreo de la recuperación de la vegetación.

II. ÁREA DE ESTUDIO Y DATOS

2.1 ÁREA DE ESTUDIO

El Área de Protección de Flora y Fauna La Primavera (APFFLP) cuenta con una superficie de 30,500 hectáreas y se localiza en la región central del estado de Jalisco al oeste de la ciudad de Guadalajara, en los municipios de Zapopan, Tala y Tlajomulco de Zúñiga, entre las coordenadas UTM 635040 E; 2 295019 N y 661 815 E; 2 273893 N zona 13 Norte (Figura 1).

Localización Geográfica del Área de Protección de Flora y Fauna
"La Primavera" (APFFLP)

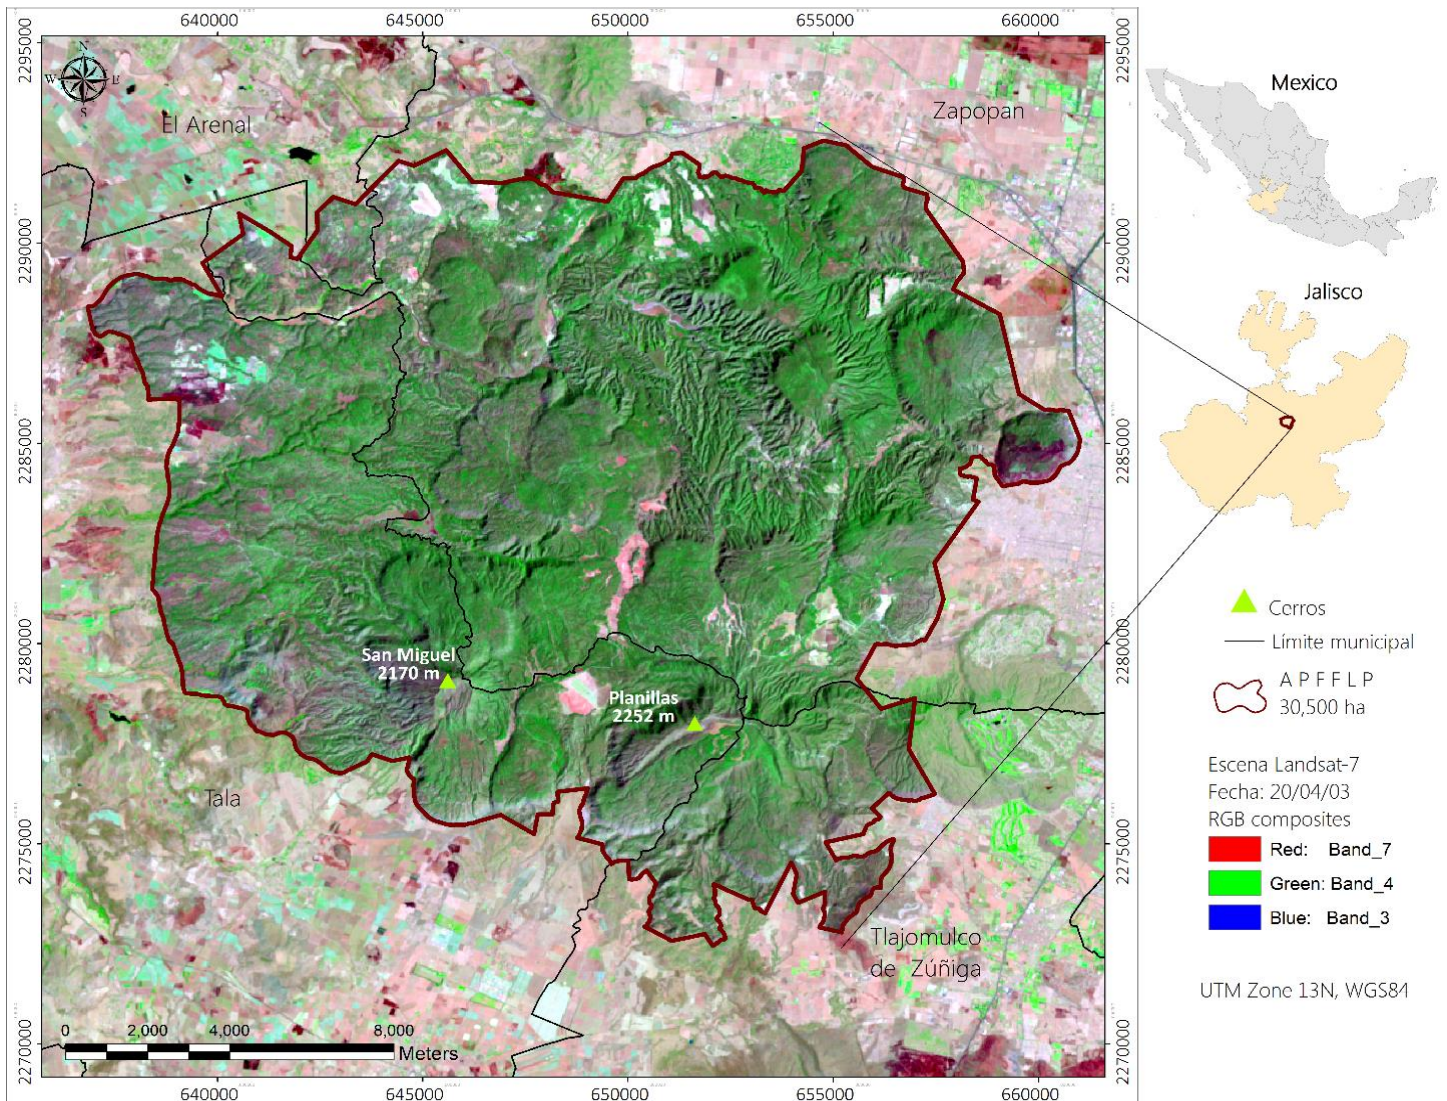


Figura 1. Localización Geográfica del área de estudio
ELABORACIÓN PROPIA

La proporción de superficie del Área Protegida en los municipios mencionados es la siguiente:

Tabla 1. Cobertura por municipio del APFFLP

Municipio	% de superficie que abarca el APFFLP
Zapopan	54.0
Tala	35.0
Tlajomulco de Zúñiga	11.0

(Secretaría de Medio Ambiente y Recursos Naturales, 2000)

El clima predominante en el APFFLP es templado subhúmedo S(w1) (w) y semicálido subhúmedo(A) C(w1) (w) ambos con lluvias en verano e invierno según la clasificación climática de Köppen, modificada por García (1987); las precipitaciones anuales en promedio fluctúan entre 800 y 1,000 mm, siendo las invernales sólo del 5% de la precipitación total. La temperatura media anual es de 20 °C; el promedio anual de humedad es de 63% y los vientos dominantes provienen del suroeste, con una velocidad máxima de 53 km/h (Secretaría de Medio Ambiente y Recursos Naturales, 2000).

El APFFLP se asienta sobre la Sierra La Primavera, la cual se ubica en la provincia fisiográfica del Eje Neovolcánico, subprovincia Guadalajara, se caracteriza por manifestaciones recientes de vulcanismo explosivo. Por sus características, la Sierra La Primavera es uno de los relieves volcánicos con más diversidad en México, donde se combinan domos anulares, mesetas, cerros y montañas que siguen las líneas de fractura de la caldera volcánica y colinas irregulares modeladas por erosión. Si bien, estas formas tienen un origen volcánico, actualmente presentan influencia de fuerzas fluviales y tectónicas. Las máximas elevaciones son el Cerro Planillas y el Cerro San Miguel situados en la parte sur. Hacia el poniente, el relieve está constituido por lomeríos y colinas. Los valles localizados alrededor son planicies originadas por deposiciones de espumas aportadas por la formación La Primavera; la variación altitudinal se encuentra entre 1,380 a 2,250 m (Secretaría de Medio Ambiente y Recursos Naturales, 2000).

De acuerdo a la clasificación FAO/ UNESCO, las unidades de suelo que constituyen el APFFLP están representadas por regosol y litosol. El regosol conforma el 92% del área natural Protegida,

el cual es derivado del intemperismo de la toba, pómez y riolita. El 8% restante de la superficie se encuentra distribuido en litosol, resultante de procesos erosivos.

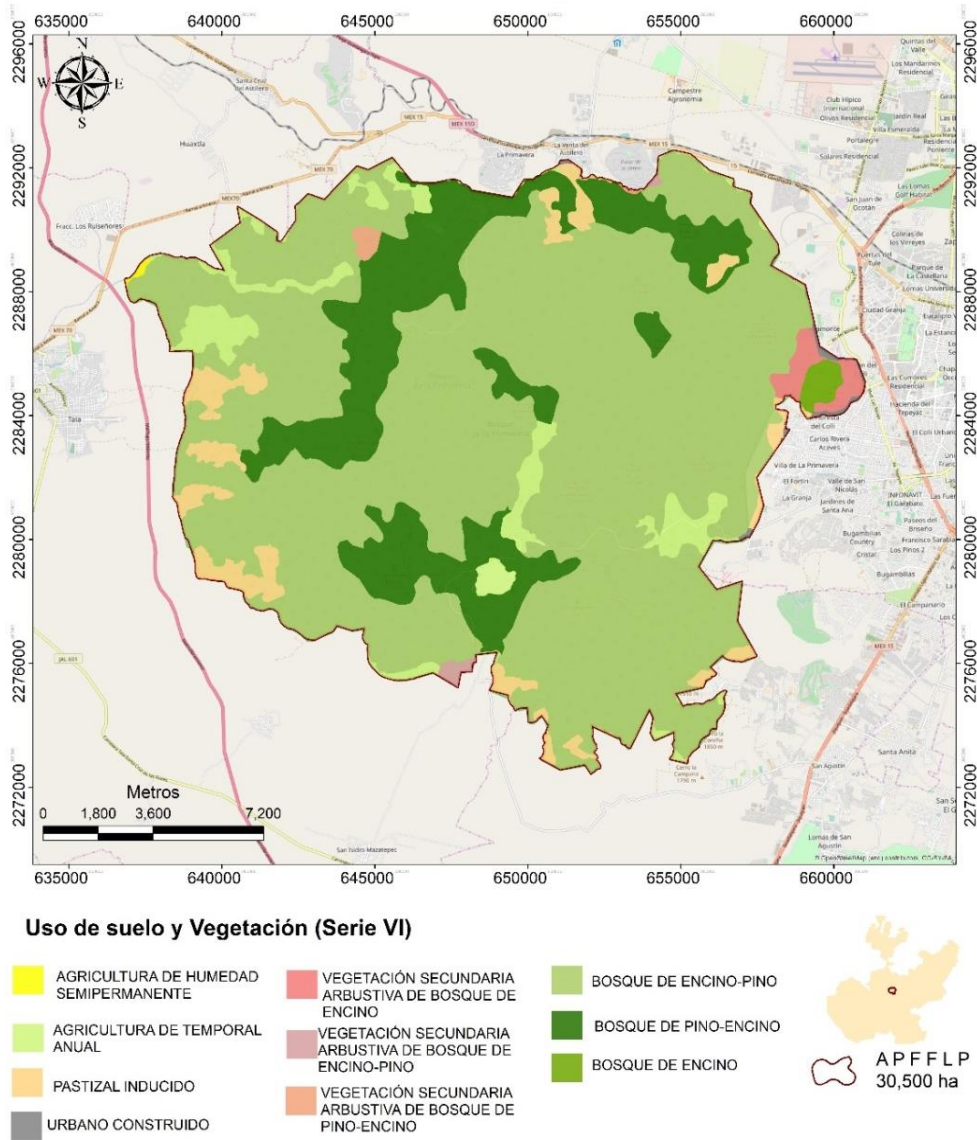


Figura 2. Mapa de uso de suelo y vegetación del área de estudio

Según la clasificación Rzedowski se encuentran cuatro tipos de vegetación: bosque de encino (*Quercus*), bosque de encino-pino (*Quercus-Pinus*), bosque de pino-encino (*Pinus-Quercus*) y bosque tropical caducifolio, así como tres comunidades vegetales riparia, rupícola y ruderal, que se desarrollan dentro de los diferentes tipos de vegetación antes mencionados. La vegetación

más representativa es el bosque de encino-pino (Figura 2), el cual se encuentra desde los 1,800 hasta los 2,225 msnm, en los puntos más altos del área conocidos como cerro San Miguel y cerro Planillas (Secretaría de Medio Ambiente y Recursos Naturales, 2000).

En cuanto a los usos de suelo, principalmente para la utilización ganadera la cual es extensiva, sin control y sólo en ciertos casos semiestabulada. El ganado es principalmente bovino con fines de producción de leche y carne. Cerca del 0.5% de la superficie del APFFLP se encuentra ocupada por construcciones irregulares. Otros usos de suelo dentro del bosque son la recreación y otra parte mucho menor para la agricultura. La tenencia de la Tierra dentro del área que comprende el bosque La Primavera, el 50% de la superficie es propiedad privada; el 35% es propiedad ejidal y/o comunal y el 15% restante es propiedad del gobierno del Estado (Secretaría de Medio Ambiente y Recursos Naturales, 2000).

2.2 DATOS

Los insumos utilizados fueron imágenes disponibles del satélite Landsat-7 para el path-row: 029-046, con una resolución espacial de 30 m, en el nivel de procesamiento L1T de reflectancia de la superficie (Landsat-7 ETM+ C1 Nivel-2), proyectadas en el sistema UTM (Universal Transverse Mercator) y elipsoide WGS84, generadas a partir de LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*) (Vermote *et al.*, 1997; Masek *et al.*, 2006) y FMASK (Zhu y Woodcock, 2012) respectivamente. Las escenas fueron descargadas del repositorio del U.S. Geological Survey (<https://earthexplorer.usgs.gov/>).

2.2.1 Datos de Referencia

Como datos de referencia se utilizaron polígonos de áreas quemadas obtenidos en campo para los años 2010, 2013 y 2016 así como también de imágenes RAPIDEYE para el año 2012, y de imágenes MODIS para los años 2005 y 2012 proporcionados por la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO). El polígono obtenido a través de imágenes RAPIDEYE fue utilizado para validar el área quemada del 2012 ya que este sensor tiene una resolución espectral más alta (5 m).

2.2.2 Especificaciones técnicas del satélite Landsat-7 ETM+

Landsat-7 es el penúltimo satélite operacional del programa Landsat del United States Geological Survey (USGS), fue lanzado en abril de 1999, con disponibilidad de imágenes a una semana de la fecha actual, viene equipado con el sensor Enhanced Thematic Mapper Plus (ETM+) que permite obtener imágenes de la superficie terrestre, las cuales pueden ser usadas en una gran diversidad de aplicaciones (Landsat Missions, 2016).

Tabla 2. Características del satélite Landsat-7 ETM+

Satélite	Modo Espectral	Bandas	Resolución Espectral (Longitud de onda μm)	Resolución Espacial (m)	Resolución Radiométrica	Resolución Temporal
Landsat-7 ETM+ (Enhanced Thematic Mapper Plus)	Multiespectral	Banda 1 - Azul	0.45 - 0.52	30	8 BITS	16 Días
		Banda 2 - Verde	0.52 - 0.60	30		
		Banda 3 - Rojo	0.63 - 0.69	30		
		Banda 4 - Infrarrojo cercano (NIR)	0.77 - 0.90	30		
		Banda 5 - Infrarrojo de onda corta (SWIR) 1 o Infrarrojo medio	1.55 - 1.75	30		
		Banda 7 - Infrarrojo de onda corta (SWIR) 2 o Infrarrojo medio	2.09 - 2.35	30		
	Térmico	Banda 6 - Térmica	10.40 - 12.50	60		
	Pancromático	Banda 8 - Pancromática	0.520 - 0.900	15		

(Tomado de Landsat Missions, USGS 2016)

El sensor ETM+ dispone de lectura en ocho canales o bandas situadas en distintos rangos del espectro electromagnético y cuantifica la radiación en 256 niveles de gris (8 bits). Las 7 primeras bandas abarcan un rango espectral de 0.45-12.50 μm , con una resolución espacial de 30 m; excepto la banda 6 que tiene una resolución espacial de 60 m. La banda 8 abarca de 0.520-0.900 μm , banda pancromática con una resolución espacial de 15 m. Con relación a la resolución temporal, Landsat-7 tarda 16 días para la obtención de imágenes del mismo punto de la tierra, por lo que en un año se pueden tomar hasta 23 imágenes con una anchura de barrido de 185 Km, dichas características se especifican en la tabla 2 (Landsat Missions, 2016).

Landsat-7 ha sido responsable del conjunto de datos espectralmente más rico, con la capacidad de registrar la radiación en un rango mucho más amplio de longitudes de onda. Sin embargo, ha

tenido algunas dificultades debido a una falla del sistema denominado Scan Line Corrector (SLC), parte del sensor ETM+ que compensa el movimiento hacia adelante del satélite durante la adquisición de las imágenes. Este corrector SLC falló en mayo de 2003, dando como resultado la pérdida de aproximadamente el 22% de los datos de cada escena adquirida a partir de entonces (Zhang *et al.*, 2007). Por lo tanto, las escenas de Landsat-7 recopiladas desde el 31 de mayo de 2003 tienen lagunas de datos, conocidos como bandeo o efecto gaps, dichas escenas adquiridas después de esta fecha se clasifican como SLC-OFF (Landsat Missions USGS, 2016) como se ilustra en la figura 3.

Sin un SLC operativo, la línea de visión del sensor ETM+ ahora traza un patrón en zigzag a lo largo de la trayectoria del satélite. Como resultado, el área con imagen se duplica, esto ocasiona que las imágenes contengan datos reales intercalados con franjas negras de datos faltantes, con un ancho que aumenta hacia el borde de la escena y que aparecen en intervalos de 33 píxeles. Sin embargo, los datos de Landsat-7 siguen siendo un componente importante del archivo Landsat, especialmente al final de la vida útil del satélite Landsat-5 en 2011 (Landsat Missions, 2016).

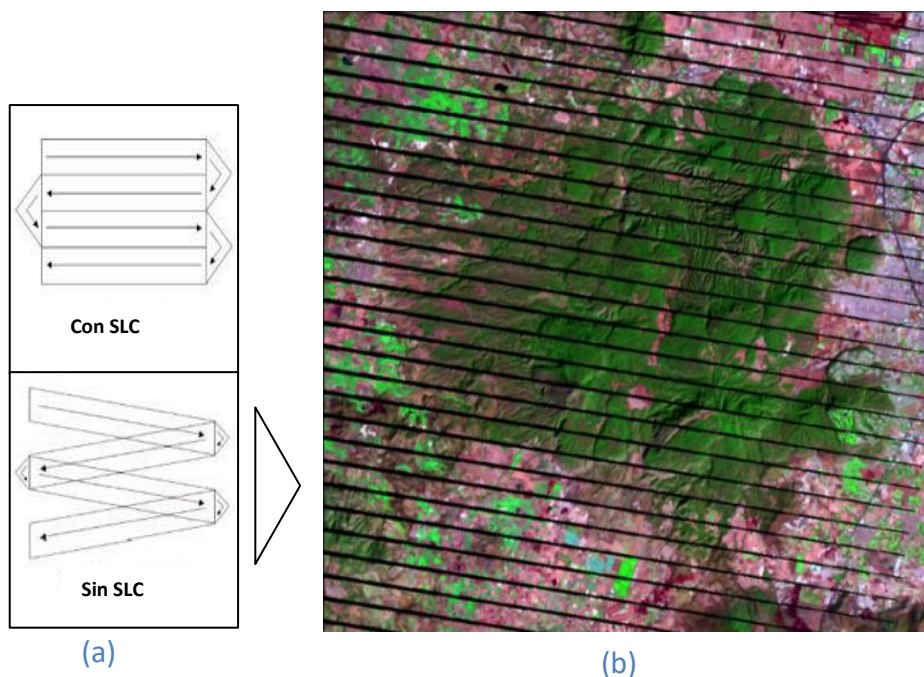


Figura 3. Fallo del sistema SLC en las imágenes Landsat-7
(a) Escáner ETM+ encendido y apagado; (b) Bando o gaps. (Fuente: USGS Landsat Project SLC-off)

III. MÉTODO

La metodología del presente trabajo se dividió en seis fases, la primera fase constó de la descarga de las imágenes Landsat-7 desde 2003 a 2016, previo a esto se realizó una consulta, en la cual se revisó que imágenes podrían ser de mayor utilidad y el pre-procesamiento enfocado en el tratamiento que se les realizó a las imágenes antes de aplicar el algoritmo, a través del lenguaje de programación IDL. La segunda fase fue la aplicación del algoritmo BFAST a las series de tiempo Landsat-7 (NDVI y NBR) para la detección de los cambios abruptos a través del lenguaje de programación R. En la tercera fase se asociaron los cambios abruptos detectados en la serie de tiempo NDVI con los incendios ocurridos dentro del área y se calculó la severidad de estos. En la cuarta fase se realizó una clasificación somera del cambio en los diferentes niveles de severidad de la quema, así como del recrecimiento o recuperación de la vegetación. La quinta fase fue la de validación de los resultados mediante polígonos de áreas quemadas obtenidos de escenas de alta resolución. Finalmente, la sexta fase correspondió a la evaluación de los resultados obtenidos. Una visión general de estas fases se muestra en la Figura 4. A continuación se describen cada una de estas fases.

3.1 PRE-PROCESAMIENTO DE LAS IMÁGENES

Para el pre-procesamiento, se descargaron todas las imágenes Landsat-7 disponibles para el área y periodo de estudio, del repositorio de la USGS (<https://earthexplorer.usgs.gov/>). Para asegurarse de tener una serie completa, se calculó la cantidad de imágenes que debería tener el acervo si el sensor produjera las imágenes con regularidad, es decir cada 16 días, dicho cálculo se realizó multiplicando el número de observaciones que obtiene Landsat-7 por año, con el número de años del periodo de estudio definido. Por lo que, el número total de imágenes que tendría que tener la serie dentro del periodo definido (2003-2016) es de 322 imágenes. Sin embargo, el acervo obtenido no estaba completo, por lo cual el total de imágenes para el periodo de estudio definido fue de 238. Todos los análisis de esta fase descritos a continuación fueron hechos en el lenguaje de programación IDL.

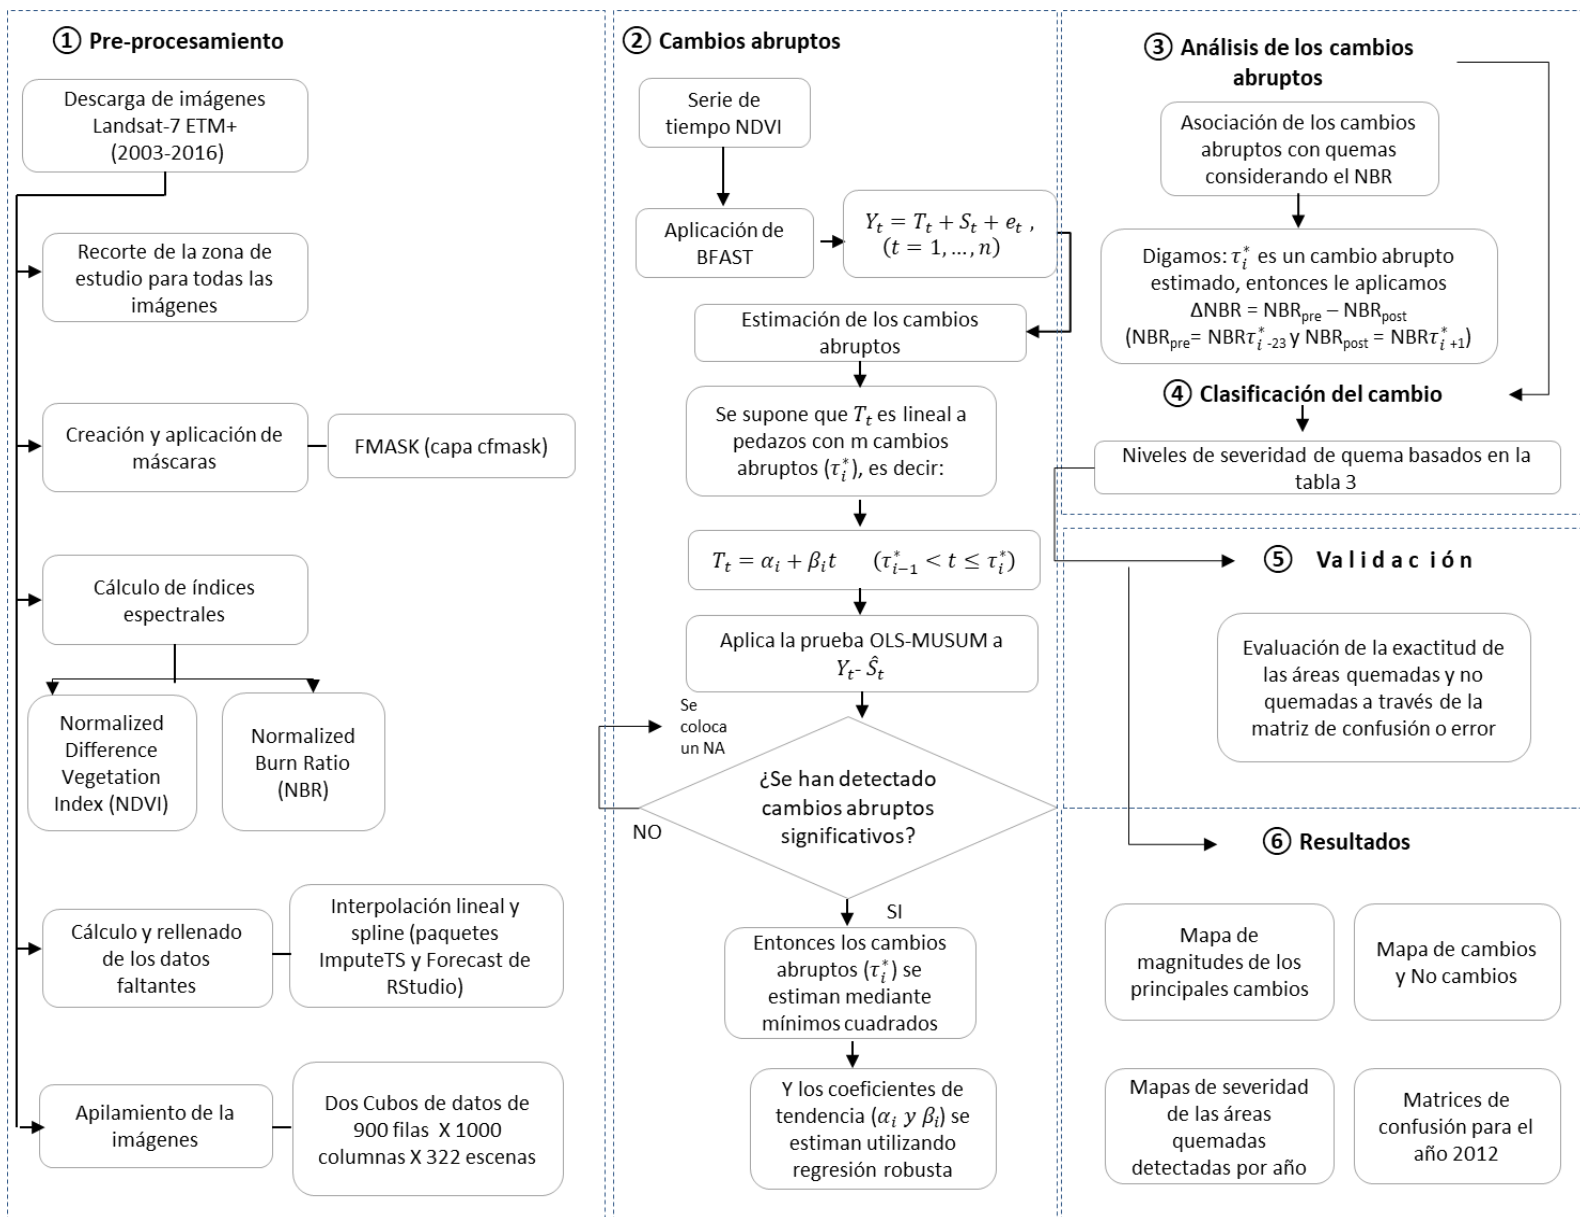


Figura 4. Diagrama de las etapas para la detección de cambios abruptos ligados a incendios

*Se describen más adelante

3.1.1 Recorte del área de estudio

El conjunto de imágenes descargadas se organizó por años para un mejor manejo y se generó un recorte en todas las bandas de 30 m de dichas imágenes ajustándolas a las siguientes coordenadas extremas X= 633375, Y=2295525 y X=663375, Y=2268525, que corresponden al área de estudio (figura 5), el tamaño de pixel se conservó a 30 m.




Figura 5. Recorte del área de estudio para las 238 imágenes Landsat-7 descargadas

(a) Imagen Landsat-7 completa, (b) Recorte del área de estudio.

3.1.2 Generación y aplicación de máscaras

Se aplicó una máscara derivada del algoritmo Fmask (Función de máscara) a las imágenes que tenían nubes y sombras de nubes (Zhu y Woodcock, 2012), el cual es un algoritmo adecuado para el uso de rutina en las imágenes Landsat, esta técnica la han empleado diferentes investigadores (White et al., 2014; Hermosilla et al., 2015; Foga et al., 2017). Los insumos de este método son el producto de reflectancia en el techo de la atmósfera (TOA) y el brillo de la temperatura (TB). El primer cálculo en Fmask consiste en usar reglas basadas en propiedades físicas de las nubes para separar píxeles de nubes potenciales (Potential Cloud Pixels o PCP) de los píxeles sin nubes. A continuación, se combinan varios parámetros como probabilidades de temperatura normalizada, variabilidad espectral y brillo, para producir una máscara de probabilidad para nubes sobre tierra y agua de manera separada. Entonces, los PCP y la máscara de probabilidad de nubes son utilizadas de manera conjunta para producir la capa de nubes dentro de un área. Para un conjunto de datos de referencia utilizados para validar Fmask de manera global, este método tiene una precisión promedio general de hasta 96.4% (Zhu y Woodcock, 2012). Al tener las máscaras se eliminaron los píxeles que contenían nubes, sombras de nubes y efecto de gaps detectados en cada una de las imágenes (figura 6), pero sin perder

información relevante. El valor de relleno para los datos enmascarados fue de “no data” para facilitar su identificación al estar fuera del rango de datos válidos.




Figura 6. Aplicación de máscaras

(a) Imagen Landsat-7 original del 30 de julio del 2005, **(b)** máscaras aplicadas a nubes y gaps en color blanco y sombras de nubes en color gris.

3.1.3 Índices espectrales (series de tiempo NDVI-NBR)

Al tener un área quemada se pueden distinguir dos señales diferentes, una que corresponde a superficies recientemente quemadas, donde la señal procede de las cenizas y el carbón como consecuencia de la combustión de la vegetación, y una segunda señal que procede como consecuencia del deterioro o pérdida de la vegetación afectada por el fuego. La persistencia de la segunda señal es muy variable, ya que depende de factores como tipo de vegetación y clima, y esta variación puede ser causada por otras razones distintas al efecto del fuego; por ello se requieren observaciones satelitales relativamente cercanas a la fecha de ocurrencia del incendio (Robinson y Bodmer, 1999).

Como podemos observar en la figura 7 las áreas quemadas presentan bajas reflectividades en el visible e infrarrojo cercano del espectro electromagnético, similares a las zonas con sombra o agua que, en ocasiones, pueden inducir a error. Además, dependiendo de la zona y de su capacidad productiva vegetal, y en periodos relativamente cortos tras un incendio, la señal de la

zona afectada podrá igualarse con la de la zona no afectada por el fuego (Key y Benson, 2006; White et al., 1996).

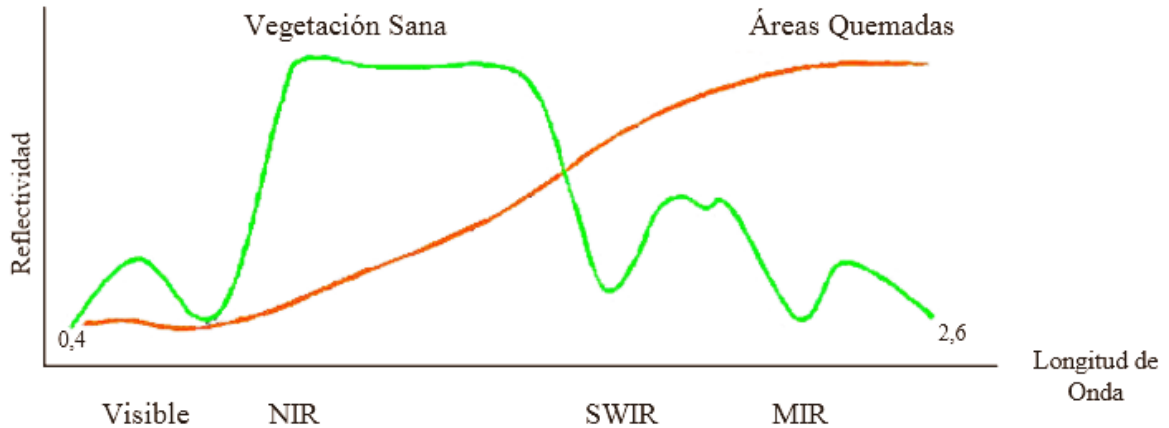


Figura 7. Respuesta espectral; vegetación no quemada vs áreas quemadas
Fuente: BAER

Existen diferentes métodos para estudiar mediante imágenes satelitales los cambios que ocurren en la vegetación; uno de ellos es la aplicación de índices de vegetación (Chuvieco, 1998). Para el área de estudio, se calcularon dos índices con el fin de detectar los cambios y optimizar la separabilidad de las áreas quemadas de las no quemadas de acuerdo a su comportamiento espectral, teniendo en cuenta que para la identificación del área quemada se consideran tres principios básicos: 1) presencia de combustible (vegetación), 2) cambios bruscos en los índices y 3) permanencia del cambio en el tiempo (Chuvieco *et al.*, 2008). Según estos supuestos, se justifica el uso de diversos índices espectrales en la identificación de áreas afectadas por incendios, entre los que se seleccionaron el Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en inglés) y el Cociente Normalizado de área Quemada (NBR por sus siglas en inglés) (Díaz-Delgado *et al.*, 2003; Epting *et al.*, 2005, Tanase *et al.*, 2011).

3.1.3.1 Cálculo de índices espectrales

Los dos índices calculados fueron el NDVI generado a partir de la banda roja (RED) e infrarrojo cercano (NIR) (Rouse *et al.*, 1973), y el NBR generado a partir del contraste espectral entre el infrarrojo cercano (NIR) y el infrarrojo medio o de onda corta (SWIR) (Key y Benson, 1999, 2006) para todas las escenas. Así también se calculó la diferencia del NBR (dNBR) a través de imágenes

pre-incendio y post-incendio, para identificar los distintos niveles de severidad de la quema (Key y Benson, 2005) (Ver ecuaciones 1, 2 y 3).

Es conveniente calcular diferentes índices de vegetación, ya que la información espectral obtenida en una sola banda no es suficiente para llegar a resaltar las diferentes respuestas espectrales de la vegetación en sus estados o condiciones. Es por eso que se realizan este tipo de operaciones entre bandas para obtener productos que faciliten su estudio. A continuación, se describen los índices utilizados NDVI, NBR y dNBR.

i. Normalized Difference Vegetation Index (NDVI)

El Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en inglés), es el índice más conocido y empleado para el estudio de la vegetación, así como también en estudios post-incendio (Chuvieco *et al.*, 2002; Trigg y Flasse, 2001; Pereira *et al.*, 1999; Rouse *et al.*, 1973). Se basa en el peculiar comportamiento radiométrico de la vegetación, relacionado con la actividad fotosintética y la estructura foliar de las plantas, permitiendo determinar la vigorosidad de la planta. Este cociente indica la diferencia de la reflectancia del infrarrojo cercano y el rojo del espectro electromagnético (Rouse *et al.*, 1973). El NDVI se define como:

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (1)$$

donde, NIR es el valor de reflectancia en el infrarrojo cercano y RED es el valor de reflectancia en el rojo. Las bandas correspondientes para el satélite Landsat-7 del NIR y RED son la 4 y 3 respectivamente.

Por definición el NDVI toma valores en el intervalo -1 a 1, siendo los valores cercanos a 1 los que indican presencia de vegetación vigorosa y los cercanos a -1 los que indican ausencia de vegetación. Dichos valores están en función de la energía absorbida o reflejada por las plantas en diversas partes del espectro electromagnético (Rouse *et al.*, 1973). Mientras que en la región del rojo los pigmentos de la hoja absorben la mayor parte de la energía que reciben, en el infrarrojo cercano, las paredes celulares de las hojas, que se encuentran llenas de agua, reflejan

la mayor cantidad de energía. En contraste, cuando la vegetación sufre algún tipo de estrés, ya sea por presencia de plagas, sequía o algún incendio leve, la cantidad de agua disminuye en las paredes celulares por lo que la reflectancia disminuye en el infrarrojo cercano y aumenta paralelamente en el rojo al tener menor absorción de clorofila. Por lo anterior la absorción en la región del rojo se debe más al contenido de pigmentos fotosintéticos activos, y la reflectancia en el infrarrojo cercano obedece a las propiedades estructurales del dosel (Jamel *et al.*, 2015).

ii. Normalized Burn Ratio (NBR)

El cociente Normalizado de área quemada (NBR por sus siglas en inglés) es un índice diseñado para identificar áreas quemadas, es similar al NDVI, excepto que es derivado a partir de porciones del infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR) del espectro electromagnético (Key y Benson, 1999, 2006). El NBR identifica las superficies afectadas por el fuego a partir de dichas bandas, cuyo intervalo de variación, al estar normalizado, queda comprendido entre -1 y 1, mediante la siguiente fórmula:

$$NBR = \frac{(NIR - SWIR)}{(NIR + SWIR)} \quad (2)$$

Siendo, NIR= reflectancia en el infrarrojo cercano y SWIR= reflectancia en el infrarrojo de onda corta; donde NIR y SWIR corresponden a las bandas 4 y 7 del satélite Landsat-7, respectivamente.

La vegetación previa al incendio tiene una reflectancia muy alta en el infrarrojo cercano y una baja reflectancia en la porción infrarroja de onda corta del espectro. Las áreas recientemente quemadas, por otro lado, tienen una reflectancia relativamente baja en el infrarrojo cercano y una alta reflectancia en la banda infrarroja de onda corta debido a la pérdida de agua en el suelo y la vegetación. Por lo cual, un valor alto de NBR indica áreas con vegetación, mientras que un valor bajo indica terreno descubierto (áreas desprovistas de vegetación) y potencialmente áreas quemadas. La distribución de los valores de NBR en áreas no quemadas típicamente se concentra en valores alrededor de cero (Normalized Burn Ratio, 2015).

El índice NBR logra una mejor discriminación de las áreas quemadas en comparación con los índices de vegetación como el NDVI ubicados en la región del visible porque la información del NIR y SWIR presenta un mayor contraste en este tipo de superficies (Roy *et al.*, 2006). Diversos estudios han enfatizado la potencialidad del NBR no sólo para delimitar las áreas quemadas sino también para evaluar el grado de severidad (Cocke *et al.*, 2005; Miller y Thode, 2007; Escuin *et al.*, 2008).

iii. Differenced Normalized Burn Ratio (dNBR)

El dNBR es utilizado para relacionar el estado de la vegetación antes y después del incendio, se estima a partir de la diferencia temporal entre el NBR pre-incendio y post-incendio (Key y Benson, 2005). El índice dNBR ha mostrado ser un método efectivo para definir diferentes niveles de severidad del área quemada (Cocke *et al.*, 2005; Norton, 2006; Miller y Thode, 2007; Weber *et al.*, 2008; Escuin *et al.*, 2008), ya que existe una gran correlación entre los valores estimados en campo y la severidad del incendio (Miller y Yool, 2002). El dNBR se define como:

$$dNBR = NBR_{pre} - NBR_{post} \quad (3)$$

donde, NBR-pre corresponde a la escena antes del incendio y NBR-post corresponde a la escena inmediatamente después del incendio. También es común denotar dNBR como ΔNBR .

Un valor alto de dNBR indica daño más severo, mientras que las áreas con valores negativos de dNBR pueden indicar un nuevo crecimiento después del incendio. La magnitud de estos valores puede variar según la escena, y la interpretación en instancias específicas siempre debe basarse en alguna evaluación de campo (Normalized Burn Ratio, 2015).

El Servicio Geológico de los Estados Unidos (USGS) a través de su programa FireMon propuso una tabla para interpretar la diferencia de NBR, con diferentes niveles de severidad de la quema, la cual se muestra a continuación en la tabla 3 (Lutes *et al.*, 2006). Dicha tabla será utilizada para la interpretación del grado de severidad de las quemadas detectadas a través de lo descrito en el apartado 3.3, con la finalidad de tener una mejor caracterización de las áreas con respecto al estado de la vegetación.

Tabla 3. Niveles de severidad de la quema

ΔNBR	Nivel de Severidad
< -0.25	Alto rebrote posterior al fuego
-0.25 a -0.1	Bajo rebrote posterior al fuego
-0.1 a +0.1	No quemado
0.1 a 0.27	Baja
0.27 a 0.44	Moderada-Baja
0.44 a 0.66	Moderada-Alta
> 0.66	Alta

3.1.4 Rellenado de datos

Un problema común de utilizar imágenes satelitales es la ausencia de datos, esta falta de datos puede surgir por diferentes razones, y es importante considerar si la falta de información inducirá sesgo en el modelo a utilizar. Muchos métodos de análisis requieren que los datos faltantes (NA's) sean reemplazados por valores razonables por adelantado.

En la estadística, este proceso de reemplazar los datos faltantes se denomina interpolación. Existen diferentes técnicas de interpolación, pero la mayoría de estos no considera uno de los aspectos importantes dentro de una serie, el tiempo. En este sentido, es necesario tener un método que interpole en las dos dimensiones, espacio y tiempo, la primera porque cada pixel dentro de las imágenes representa un espacio en la Tierra y el segundo porque se tiene cierto número de observaciones que forman dicha serie a través del tiempo.

La funcionalidad provista hace que el paquete *imputeTS* y el paquete *Forecast* implementados en el lenguaje de programación estadística R sean una buena opción para el relleno de series temporales (Moritz y Bartz, 2017), antes de aplicar cualquier otro proceso o algoritmo que requiera un cubo de información o serie de tiempo completo (sin NA's) como es el caso de BFAST. Por lo cual, se utilizaron estos dos paquetes para la interpolación de NA's.

Para el caso de *imputeTS*, la función utilizada fue "na. interpolation" (Moritz, 2016), que incluye tres tipos de interpolación, lineal, spline y stineman, de las cuales se aplicaron las dos primeras. En el caso de *Forecast*, se utilizó la función "na. interp" (Hyndman, 2018).

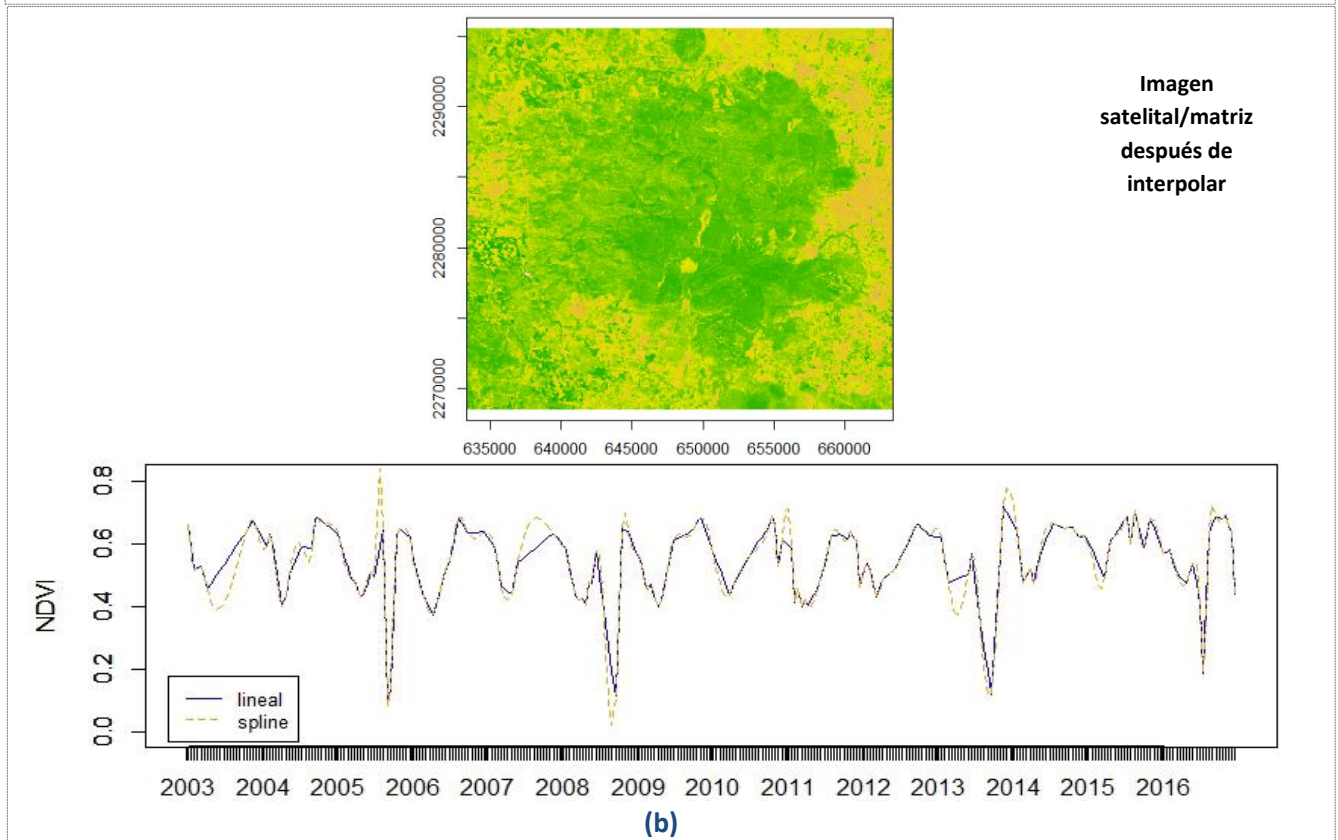
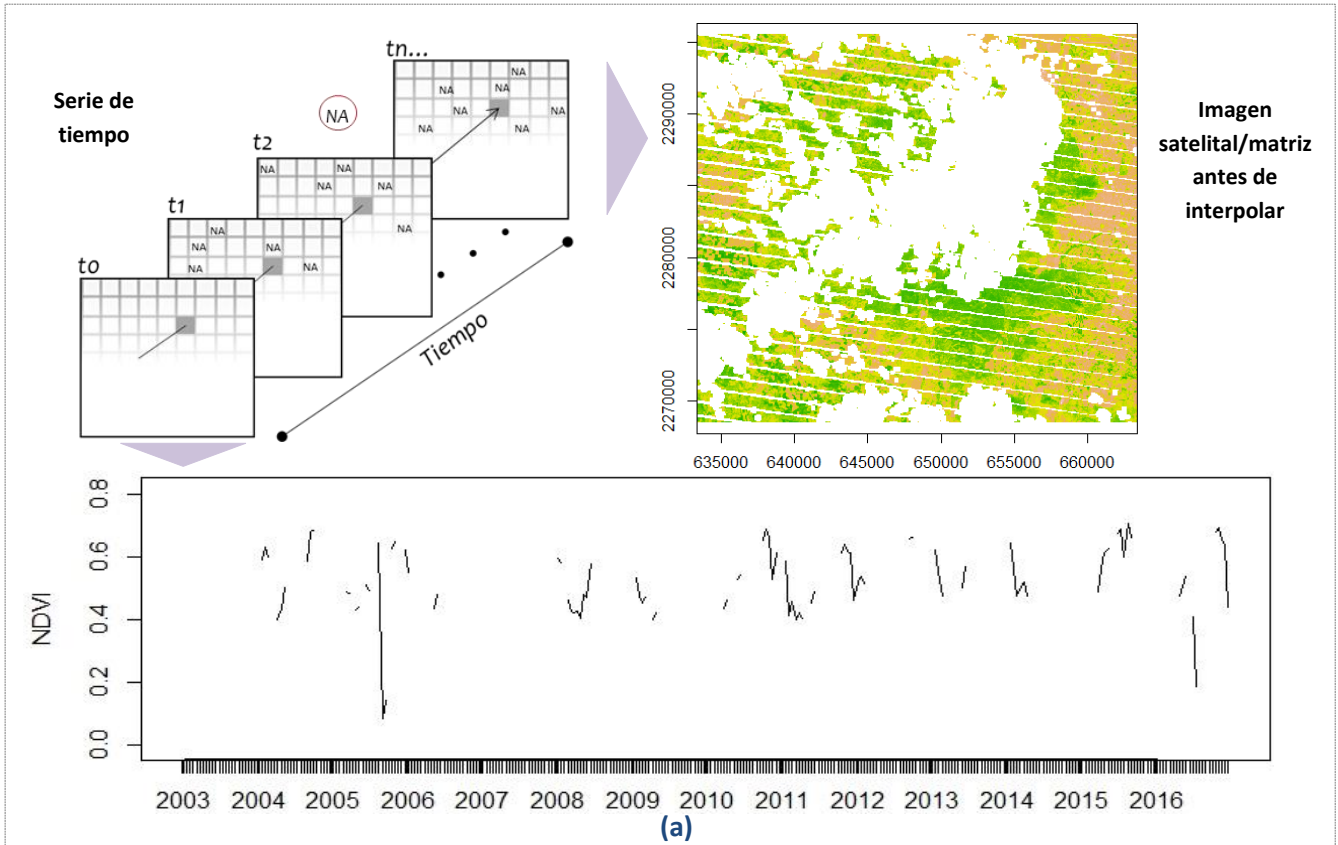


Figura 8. Rellenado de datos faltantes (NA's)

(a) Representación de la serie de tiempo con NA's. (b) Aplicación de la interpolación lineal y spline en la serie de tiempo.

A través de dichas interpolaciones fue posible que después de aplicadas las máscaras, la serie de tiempo fuera rellenada tanto en tiempo por imágenes faltantes, como en espacio debido a las nubes, sombras de nubes y gaps (figura 8). Sólo se muestran los resultados de la interpolación lineal y spline de la función “na. interpolation”, debido a que la interpolación realizada con la función “na. interp”, arrojó los mismos resultados que la interpolación lineal. Al utilizar estos dos métodos fue posible cuantificar el impacto que tiene rellenar la serie de tiempo en el desempeño de BFAST (ver sección 4.3). Cabe mencionar, que el rendimiento de la interpolación lineal siempre dependerá de las características de la serie temporal de entrada.

3.1.5 Apilamiento de imágenes

Una vez rellenada la serie de tiempo y para tener un mejor manejo de esta (poder analizarla pixel por pixel) se apilaron todas las escenas de NDVI y NBR con la información espacial y temporal de cada pixel, representando el área de interés en una matriz espacial de 1000 columnas por 900 filas y por 322 escenas (figura 9). El cubo o matriz de NDVI fue utilizado como datos de entrada para la aplicación del algoritmo en la detección de los cambios abruptos. Por otra parte, el cubo o matriz del NBR fue utilizado para asociar los cambios abruptos detectados en el cubo del NDVI con áreas quemadas.

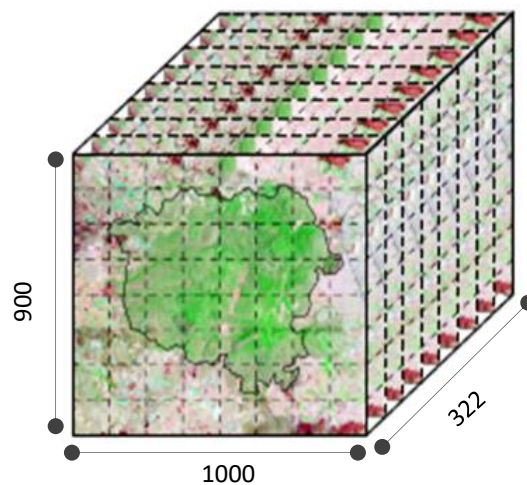


Figura 9. Representación de los cubos de NDVI y NBR

3.2 BREAKS FOR ADDITIVE SEASONAL AND TREND (BFAST)

Para detectar las perturbaciones, se propone un enfoque genérico de detección de cambios para series de tiempo mediante el algoritmo BFAST (Verbesselt *et al.*, 2009, 2010, 2012), usando el paquete BFAST implementado en el lenguaje de programación R versión 3.5.0 (<http://cran.r-project.org/package=bfast>).

Este algoritmo ha sido diseñado para dividir una serie temporal en una serie de segmentos estables basados en una serie de interrupciones (Verbesselt *et al.*, 2010), para seleccionar la ruptura más importante en una serie temporal, si la hay (Verbesselt *et al.*, 2012). El método BFAST (Rupturas en tendencia y estacionalidad aditivas) integra la descomposición de la serie de tiempo en componentes de tendencia, estacionalidad y ruido en la detección de cambios. La Figura 10 ilustra la aplicación de BFAST a un pixel típico de la zona de estudio que presenta vegetación de encino-pino, en el que se muestra como se descompone la serie de tiempo. Se puede ver que se detectan tres cambios abruptos en la componente de tendencia en diferentes años de la serie de tiempo NDVI.




Figura 10. Descomposición de la serie de tiempo con BFAST
A) Datos de entrada color negro (Y_t); B) componente estacional (S_t); C) componente de tendencia (T_t); D) componente de ruido (e_t). Se detectan tres puntos de cambio en la tenencia (línea punteada).

Los cambios se detectan mediante la identificación de puntos de ruptura (denominados breakpoints o cambios abruptos) resultantes del proceso de descomposición. BFAST estima iterativamente el tiempo, el número de cambios abruptos, y los caracteriza por su magnitud (Verbesselt *et al.*, 2010). Este método es aplicado a nivel mundial para detectar cambios abruptos, debido a su fácil aplicación, probada eficacia y garantías teóricas sobre su funcionamiento. (Verbesselt *et al.*, 2010; Verbesselt *et al.*, 2012; DeVries *et al.*, 2015; Dutrieux *et al.*, 2015). Además, BFAST se puede aplicar a cualquier conjunto de datos obedeciendo una representación aditiva como la mostrada en Eq. 4 y no está limitado a NDVI.

El algoritmo utiliza el procedimiento iterativo STL (Seasonal-Trend), para descomponer la serie temporal, STL utiliza un suavizador de sensibilidad LOESS (LOcally wEighted regreSSion Smoother) para descomponer la serie temporal (Verbesselt *et al.*, 2010).

Para el presente caso de estudio se siguieron cuatro pasos principales para detectar los cambios en cada uno de los píxeles de la serie de tiempo y relacionarlos con áreas quemadas: (1) se utilizó un modelo de descomposición aditiva para ajustar iterativamente una tendencia lineal a pedazos; (2) se estimaron los cambios abruptos y se calculó la magnitud; (3) se ligaron los cambios a incendios; y (4) se clasificó preliminarmente el tipo de cambio (área quemada, recrecimiento o recuperación de la vegetación). Estos pasos se describen con más detalle a continuación.

3.2.1 Descomposición del modelo aditivo de tendencia y temporalidad

Utiliza un modelo de descomposición aditiva que ajusta iterativamente una tendencia lineal a pedazos conjuntamente con un modelo estacional. El algoritmo es capaz de descomponer la serie en componentes de tendencia (T_t), estacionalidad (S_t) y de ruido (e_t), para detectar y caracterizar cambios dentro de series de tiempo (Verbesselt *et al.*, 2010). El modelo puede expresarse como:

$$Y_t = T_t + S_t + e_t, \quad (t = 1, \dots, n) \quad (4)$$

donde, Y_t son los datos observados en el tiempo t , T_t es el componente de tendencia, S_t es el componente estacional y e_t es el componente restante o ruido.

Se supone que T_t es lineal por tramos con pendientes específicas por segmento e intercepciones en $(m + 1)$ segmentos diferentes. Por lo tanto, hay m cambios abruptos $\tau_1^*, \dots, \tau_m^*$, de manera que:

$$T_t = \alpha_i + \beta_i t \quad (\tau_{i-1}^* < t \leq \tau_i^*) \quad (5)$$

donde, $i = 1, \dots, m$ y definimos $\tau_0^* = 0$ y $\tau_{m+1}^* = n$

La intersección α_i y la pendiente β_i de las funciones lineales consecutivas, son usadas para derivar la magnitud y la pendiente del cambio gradual entre los cambios abruptos detectados. La magnitud del cambio abrupto es derivado de la diferencia entre T_t en τ_{i-1}^* y τ_i^* , de modo que:

$$\text{magnitud} = (\alpha_{i-1} - \alpha_i) + (\beta_{i-1} - \beta_i)t \quad (6)$$

Del mismo modo, la componente estacional se fija entre cambios abruptos. Además, los p cambios abruptos estacionales pueden ocurrir en momentos diferentes a los m cambios abruptos del componente de tendencia.

BFAST emplea una estimación para la detección de cambios fenológicos dentro de una serie de tiempo de imágenes satelitales. Supóngase que los cambios abruptos estacionales sean dados por $\tau_1^\#, \dots, \tau_p^\#$, y de nuevo define $\tau_0^\# = 0$ y $\tau_{p+1}^\# = n$. Entonces suponiendo que S_t es una función armónica para $\tau_{j-1}^\# < t \leq \tau_j^\#$ ($j = 1, \dots, p$) y k el número de términos armónicos:

$$S_t = \sum_{k=1}^k a_{j,k} \sin\left(\frac{2\pi kt}{f} + \delta_{j,k}\right) \quad (7)$$

donde, los parámetros desconocidos son las amplitudes de los segmentos específicos $a_{j,k}$ y la fase $\delta_{j,k}$ y f es la frecuencia conocida (en este caso, $f = 23$ observaciones anuales para una serie cronológica de 16 días).

3.2.2 Detección de cambios abruptos en series de tiempo NDVI

Detectar los cambios dentro de una serie de tiempo de imágenes satelitales es una tarea demandante debido a que tienen por sí mismo cambios estacionales, además del ruido que se origina, como errores geométricos, la dispersión atmosférica y nubes que pueden generar falsos

cambios (Verbesselt *et al.*, 2012), por lo que resulta importante comprender los procesos de acción de conductores naturales y antrópicos que generan dichos cambios.

Siguiendo el modelo de descomposición los puntos de interrupción de tendencia τ_i^* ($i = 1, \dots, m$) y su correspondiente intercepción del segmento específico α_i y β_i son determinados junto con los puntos de interrupción estacionales $\tau_j^\#$ ($j = 1, \dots, p$) y el segmento de amplitud específico correspondiente $a_{k,j}$ y la fase $\delta_{k,j}$ para frecuencias $2\pi/k$ ($k = 1, 2, 3$).

Además, el algoritmo debe determinar el número de segmentos requeridos en la tendencia ($m + 1$) y el componente estacional ($p + 1$), respectivamente. Sin embargo, una vez que se conocen los puntos de corte, la estimación de los parámetros de tendencia y temporada es directa. La posición óptima de estos puntos de corte se determina minimizando la suma residual de cuadrados, y el número óptimo de puntos de corte se puede determinar mediante indicadores como el BIC (Criterio de Información Bayesiano) propuesto por Bai y Perron (2003) que argumentan es un procedimiento de selección adecuado en muchas situaciones (Zeileis, 2011).

Antes de ajustar los modelos lineales por partes y de estimar los puntos de ruptura, se establece estadísticamente la existencia de tales puntos de corte en la serie temporal, a través de la prueba de sumas móviles (MOSUM) basada en residuos de mínimos cuadrados ordinarios (OLS), la cual evalúa si se producen uno o más puntos de interrupción (Zeileis, 2005). Si la prueba indica un cambio significativo ($p < 0.05$), el número de puntos de ruptura se estima utilizando BIC, y también se estiman la fecha y el intervalo de confianza de la fecha para cada descanso. Además, el método provee un intervalo de confianza al $(1-\alpha)$ % de la fecha de corte o ruptura. El nivel de significancia utilizado fue de $\alpha = 0.05$. Sin embargo, BFAST permite utilizar cualquier valor de α en $[0,1]$. En resumen, el procedimiento iterativo se inicia con una estimación de \hat{S}_t a partir de una descomposición estándar de la tendencia y temporalidad. La estimación de los parámetros se realiza iterando a través de los siguientes pasos:

1. Si la prueba OLS-MOSUM indica que se están produciendo puntos de interrupción en el componente de tendencia, el número y la posición de los puntos de interrupción de

tendencia $\tau_1^*, \dots, \tau_m^*$ se estiman por mínimos cuadrados a partir de los datos desestacionalizados $Y_t - \hat{S}_t$.

2. Los coeficientes de tendencia α_i y β_i se estiman (dados los puntos de interrupción de la tendencia) usando una regresión robusta. Esto produce la estimación de tendencia $\hat{T}_t = \hat{\alpha}_i + \hat{\beta}_i t$ basado en la ecuación (5).
3. Si la prueba OLS-MOSUM indica que los puntos de corte se están produciendo en el componente estacional, el número y la posición de los puntos de corte estacionales $(T_1^\#, \dots, T_p^\#)$ son estimados a través de mínimos cuadrados de los datos sin tendencia $Y_t - \hat{T}_t$.
4. Mediante regresión robusta se estiman los coeficientes estacionales $\gamma_{j,k}$ y $\theta_{j,k}$ (teniendo en cuenta los puntos de corte de temporada). Esto produce el componente estacional $\hat{S}_t = \sum_{k=1}^k \alpha_{j,k} \sin\left(\frac{2\pi kt}{f} + \delta_{j,k}\right)$ basado en la ecuación (7).

Estos pasos se repiten hasta que un criterio de convergencia de los estimadores se satisface. Cabe resaltar que para este estudio solo se enfocó en los cambios abruptos o puntos de corte o interrupción detectados en la tendencia.

3.3 ASOCIACIÓN DE LOS CAMBIOS ABRUPTOS CON ÁREAS QUEMADAS

Con el fin de señalar de qué tipo de perturbación se trata al ser detectados cambios abruptos dentro de la serie de tiempo NDVI, se realizó lo siguiente a través del lenguaje de programación R: Una vez detectados los cambios abruptos (τ_i^*) en la serie de tiempo NDVI, se asociaron estos con eventos de fuego o quemadas considerando el índice de Quemaduras Normalizado (NBR). Para este fin, se utilizó la serie de tiempo o cubo de NBR para seleccionar el pixel de la fecha correspondiente al cambio abrupto estimado, y calcular una diferencia entre estos (ΔNBR). De acuerdo con Escuin *et al* (2008) para hacer la diferencia las observaciones fueron seleccionadas

de tal manera que la fecha de la observación después del incendio fuera la más cercana a su ocurrencia, mientras que la observación anterior correspondiera a un año antes, con el objetivo de minimizar las diferencias atribuibles a las condiciones de iluminación o cambios fenológicos. Es decir, las observaciones utilizadas fueron $NBR_{pre} = NBR_{\tau_i^* - 23}$ y $NBR_{post} = NBR_{\tau_i^* + 1}$, siendo τ_i^* un cambio abrupto estimado, - 23 la observación correspondiente a un año atrás (temporada fenológica) de la misma fecha y +1 la observación correspondiente inmediatamente después de la quema a partir del τ_i^* estimado. Este procedimiento devuelve dNBR y los puntos de cambio, estos están descritos en apartado de resultados.

3.4 CLASIFICACIÓN DEL CAMBIO

Después de calcular dNBR (τ_i^*) como se señala en la sección 3.3, los resultados fueron clasificados en base en la tabla 3, propuesta por el Servicio Geológico de los Estados Unidos (USGS), descrita anteriormente en el apartado 3.1.3.1 (iii). Como una primera aproximación, dicha clasificación se utilizó para la interpretación del nivel de severidad de las quemas detectadas con la finalidad de tener una mejor caracterización de las áreas con respecto al estado de la vegetación.

La clasificación se realizó en el software ArcMap 10.3.1 a través del método intervalo manual, ya permite definir sus propias clases, puede agregar manualmente cortes de clase y establecer los rangos que sean apropiados para los datos, realizando los ajustes que sean necesarios. Obteniendo así la clasificación severidad de la quema por año.

3.5 PRUEBAS DE SIMULACIÓN

Realizar estudios de simulación es importante ya que es necesario cuantificar la robustez del algoritmo usado en un ambiente controlado, y que evalué las limitantes del método.

En esta sección se evaluaron las limitantes del método en función de los problemas que se encontraron en los datos (falta considerable de datos). Por lo cual, se simuló una serie de

tiempo de NDVI de 16 días con diferentes niveles de ruido, datos faltantes y eventos de perturbación en la componente de tendencia para poder cuantificar la robustez de BFAST en un entorno controlado. Sin embargo, crear series de tiempo simuladas que contengan información combinada sobre fenología, la variabilidad climática interanual, eventos de perturbación y la contaminación de la señal, es un desafío, debido al ruido inherente generado por nubes, sombras de nubes y gaps en el caso de las imágenes Landsat-7 (Zhang *et al.*, 2009).

Se agregaron uno y dos puntos de cambio (perturbaciones), se borraron datos de forma aleatoria a las series simuladas utilizando los parámetros de la tabla 4 para un punto de cambio y la tabla 5 para dos puntos de cambio. Se realizaron 1000 simulaciones por cada método de interpolación (lineal y spline) y por cada combinación de los parámetros utilizados. Como se puede ver en la tabla 4 el parámetro h (propio de BFAST) también fue variado para observar con qué valor de h BFAST detecta mejor los cambios abruptos dentro de la serie de tiempo.

Tabla 4. Parámetros de la simulación de un punto de cambio de la serie de tiempo NDVI

Parámetros	Valor	Parámetros	Valor
σ ruido	0.02, 0.05, 0.07	σ ruido (fijo)	0.02
Dato faltante	40%, 50%, 60%	Dato faltante	40%, 50%, 60%
h (fija)	0.15	h	0.15, 0.23, 0.45

Tabla 5. Parámetros de la simulación de dos puntos de cambio de la serie temporal NDVI

Parámetros	Valor
σ ruido (fijo)	0.02
Dato faltante	40%, 50%, 60%
h	0.15, 0.23, 0.45
l	10, 20, 30, 40, ..., 140

Para la serie de tiempo NDVI con un punto de cambio se modificaron el valor de h y el ruido para observar la robustez del algoritmo (la precisión de estimar el número y el momento del cambio) de los cuales se obtuvieron los porcentajes de puntos correctamente identificados y el Error Cuadrático Medio (MSE).

En la serie simulada donde se agregaron dos puntos de cambio, se cuantificó la frecuencia de identificación correcta de dos puntos de cambio como función de la distancia entre estos, por lo cual se utilizaron diferentes distancias representadas como l en la tabla 5. A partir de éstas se obtuvieron los porcentajes de puntos correctamente identificados, la sobreestimación y subestimación de estos a partir de cierta distancia.

Cabe mencionar que BFAST puede estimar un punto de cambio correctamente cuando el porcentaje de datos faltantes es menor o igual al 40% y con un valor de $h=0.23$, y puede estimar dos puntos de cambio correctamente a partir de las distancias $l=50$ y $l=70$. Los resultados de las simulaciones realizadas se muestran más adelante.

3.6 VALIDACIÓN

Debido a que en algunas áreas es muy difícil encontrar datos de validación para dar cuenta de todos los tipos de cambios que ocurren en los diferentes ecosistemas, se validó la capacidad del método empleado para determinar áreas quemadas, a través del cálculo de exactitud del mapa de quema solo del año 2012 derivados de los cambios abruptos detectados por BFAST.

3.6.1 Evaluación de la exactitud

La exactitud de los datos espaciales ha sido definida por el Servicio Geológico de los Estados Unidos (USGS) como: “La cercanía de los resultados de observaciones, cálculos o estimaciones con los valores verdaderos o los valores aceptados como verdaderos” (USGS, 1990). Sin embargo, debe decirse que la “verdad” tiene una cierta dimensión subjetiva (Janssen y Van der Wel, 1994).

La evaluación de exactitud de los mapas de quemados obtenidos a través del algoritmo con imágenes Landsat-7 se efectuó comparando dos fuentes de información: a) el mapa del área quemada de 2012 derivado del algoritmo, y b) la información de referencia que comprende el polígono del área quemada de 2012 generado con imágenes de alta resolución de RAPIDEYE proporcionado por la CONABIO, asumiendo esta información como “verdad en el terreno”.

Utilizando el programa ArcMap 10.3.1, los polígonos de referencia de área quemada y no quemada (obtenido a través de RAPIDEYE) se sobrepusieron a los identificados con el algoritmo de áreas quemadas y no quemadas, para obtener la información de las ubicaciones interceptadas concordancia/discordancia entre ambos. La información obtenida se organizó en una matriz de confusión o matriz de error (Congalton, 1991; Chuvieco, 1996; Mas et al., 2003), para calcular la precisión global y los errores de omisión y comisión asociados a la exactitud del productor y del usuario.

En la matriz de confusión ilustrada en la tabla 6, la diagonal de la matriz expresa el número de sitios de verificación para los cuales hay concordancia entre el mapa y los datos de referencia, mientras que los marginales indican errores de asignación.

Tabla 6. Ejemplo de una matriz de confusión o matriz de error

		j = Columnas <u>MAPA</u>			Total filas n_{i+}
		1	2	k	
i = Filas <u>REFERENCIA</u>	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total columnas n_{+j}		n_{+1}	n_{+2}	n_{+k}	n

La suma de valores de la diagonal (superficie coincidente quemada y no quemada en los datos de referencia y mapa) dividido entre el total de píxeles evaluados, expresa la confiabilidad o precisión global del mapa, a través de la siguiente fórmula:

$$Precisión\ Global = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (8)$$

El error de comisión representa la proporción de sitios de verificación cartografiada en una cierta clase que en realidad pertenecen a otra. El error de omisión se refiere a la proporción de sitios de verificación omitidos en cierta clase (Aronoff, 1982; Chuvieco, 1996).

Existen también índices que dan cuenta de la confiabilidad de cada una de las clases como: la exactitud del usuario y productor (Ecuaciones 9 y 10) relacionados respectivamente con los errores de comisión y omisión. La exactitud del usuario indica que un pixel o clase clasificado en el mapa como Q represente esa clase Q en el terreno y la exactitud del productor indica que un pixel o clase de referencia sea correctamente clasificado (Mas et al., 2003).

$$Precisión\ del\ usuario \quad i = \frac{n_{ii}}{n_{i+}} \quad (9)$$

$$Precisión\ del\ productor \quad j = \frac{n_{jj}}{n_{+j}} \quad (10)$$

IV. RESULTADOS

A continuación, se presentan los resultados de los procesos anteriormente descritos. Se describen los resultados de las simulaciones, así como los mapas de cambios, de magnitud del cambio, las áreas quemadas detectadas, la severidad de las quemadas detectadas y finalmente la evaluación de la exactitud de las áreas quemadas detectadas a través del método.

4.1 DISPONIBILIDAD DE DATOS PARA EL ÁREA DE ESTUDIO

En general, si el sensor satelital funcionase perfectamente se tendría un acervo completo de 322 imágenes en el periodo 2003-2016 ya que Landsat-7 por cada año obtiene aproximadamente 23 imágenes. Sin embargo, la disponibilidad de escenas para el área de estudio en el periodo comprendido, es de 238 imágenes. Teniendo un 26.09% de escenas faltantes, siendo 2014, 2015, 2016 los años dónde se concentra la mayoría de las imágenes disponibles y con menor disponibilidad los años 2003, 2007, 2006 y 2010. En cuanto a la distribución temporal de estas, los meses con un mayor número de imágenes son agosto, enero y mayo. Las imágenes existentes para cada año y mes se pueden observar en la figura 11. Además de ese total (238) fue necesario considerar aquellas escenas que, estando disponibles presentaban amplia presencia de nubes, aumentando el porcentaje de datos faltantes.




Figura 11. Total de imágenes Landsat-7 disponibles para la escena 29/46 por año y mes

Como ya se mencionó, debido a que existían imágenes por nubosidad excesiva y los gaps que ya vienen en las imágenes Landsat-7, se calculó el porcentaje de NA's de las escenas utilizadas, dicho porcentaje se puede observar en la figura 12, en la cual se observa que la mayor cantidad de NA's se concentra en 94 escenas. Sin embargo, aunque este número es elevado, también se puede observar que hay muchas más imágenes con un menor porcentaje NA's, aproximadamente 156 escenas presentan menos del 50% de NA's.

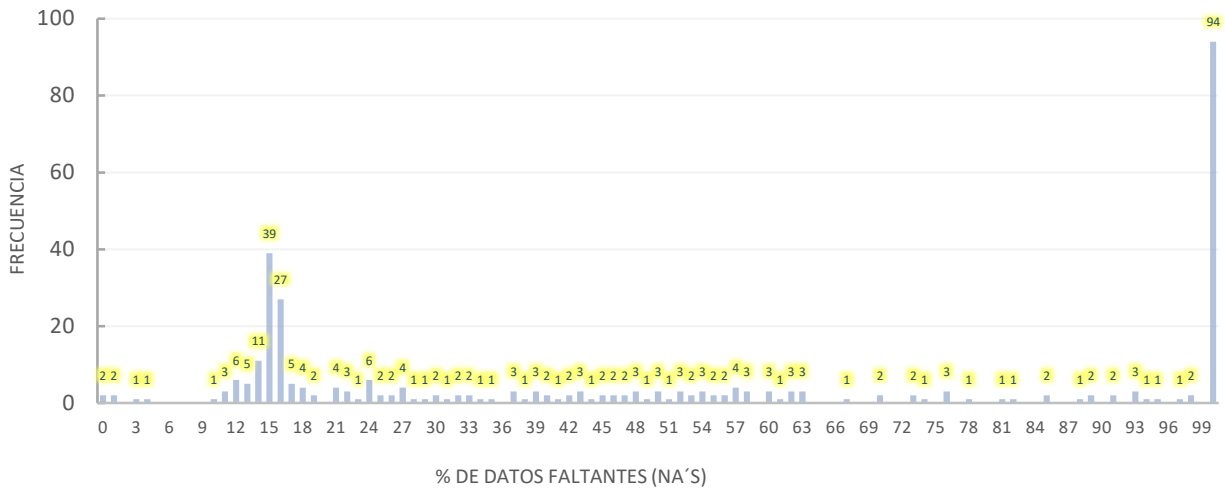


Figura 12. Histograma del porcentaje de datos faltantes (NA's) en las imágenes Landsat-7 para el APFFLP

4.1.1 Áreas quemadas registradas en el área de estudio a través de datos de campo y derivadas por imágenes de satélite

La disponibilidad de datos de campo (polígonos de áreas quemadas) para el área de estudio es escasa, algunas veces por el difícil acceso a dichas áreas o por la dimensión de éstas ya que algunas veces las áreas quemadas son muy grandes. Los datos de las áreas quemadas disponibles para el área de estudio se ilustran en la figura 13, se muestra que sólo se cuenta con polígonos de áreas quemadas obtenidos en campo para los años 2010, 2013 y 2016. Para los años 2005 y 2012, se tienen polígonos de las áreas quemadas derivadas del satélite MODIS y se tiene también un polígono del área quemada de 2012 derivada del satélite RAPIDEYE. Todos estos datos fueron proporcionados por la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO).


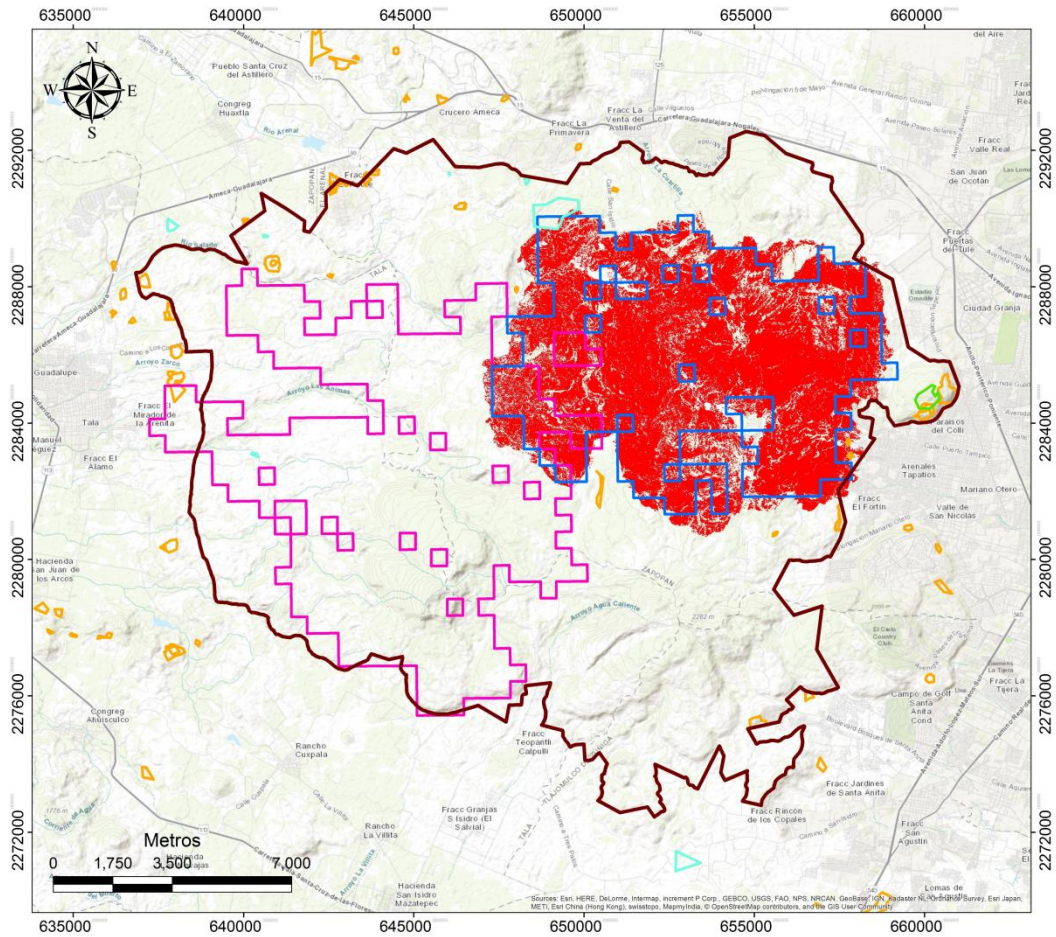


Figura 13. Áreas quemadas registradas en el área de estudio
ELABORACIÓN PROPIA.

4.2 EJEMPLOS DE ESCENAS CON DIFERENTES PORCENTAJES DE DATOS FALTANTES Y RELLENADAS

Como se mencionó en el apartado 3.1.4, los datos disponibles para el área de estudio contienen datos faltantes debido a la presencia de nubes, sombras de nubes y gaps, por lo cual los datos utilizados tienen diferentes porcentajes de datos faltantes (NA's) en la mayoría de las escenas que conforman la serie de tiempo.

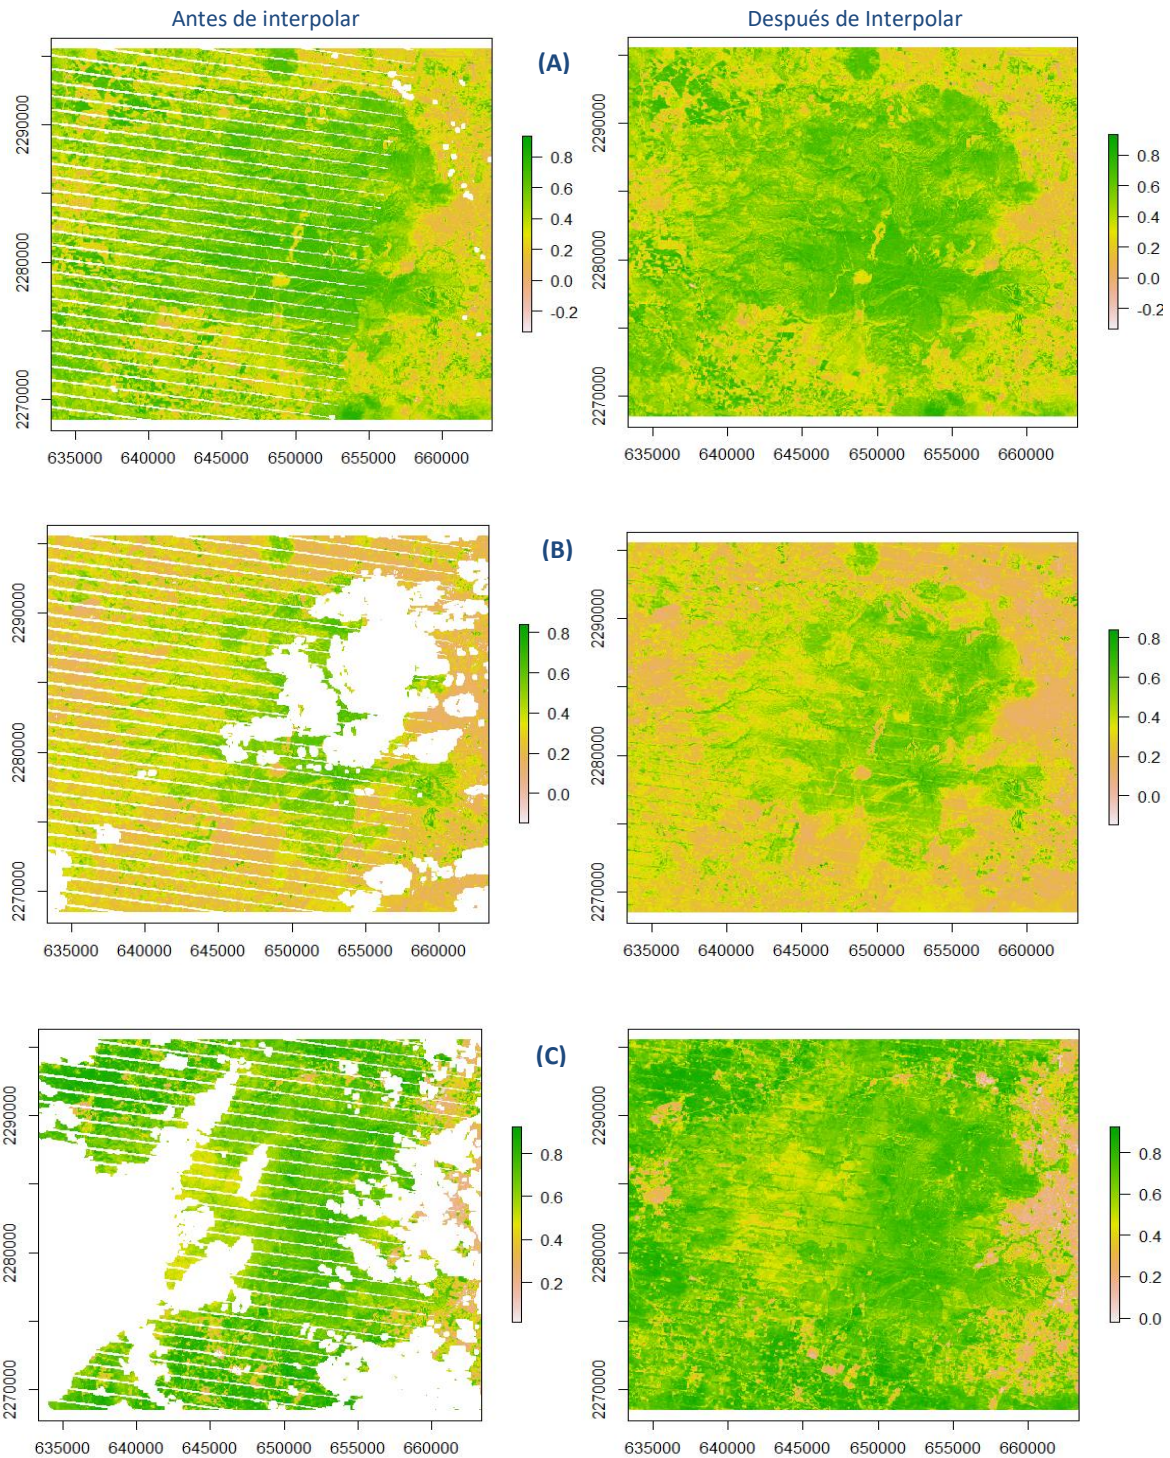


Figura 14. Rellenado de datos faltantes del APFFLP

(A) Escenas NDVI con 10% de NA's; (B) Escenas NDVI con 30% de NA's; (C) Escenas NDVI con 50% de NA's.

En la figura 14 se muestran algunas de las escenas con 10%, 30% y 50% de datos faltantes (NA's) antes y después de ser rellenadas a través del método de interpolación lineal. Podemos

observar que cuándo se tiene un 10% de datos faltantes se recuperan las estructuras mientras que con un 30% o más de datos faltantes quedan algunos artefactos en las escenas.

4.3 PRUEBAS DE SIMULACIÓN EN SERIES DE TIEMPO NDVI

En la figura 15 se muestra un ejemplo de series simuladas agregando un punto de cambio (a) y dos puntos de cambio (b) en la componente de tendencia, la serie de datos simulados es la suma de las series simuladas de tendencia, estacionalidad y ruido, y se utilizó como datos de entrada (Y_t) en BFAST de acuerdo a lo descrito en el punto 3.5.




Figura 15. Series de tiempo NDVI simuladas en la componente de tendencia
(a) Agregando un cambio abrupto y (b) agregando dos cambios abruptos.

4.3.1 Identificación de un punto de cambio

El porcentaje de cobertura total de un punto de cambio identificado como función del porcentaje de datos faltantes, método de interpolación usado y ruido (σ) se resume en la figura 16. En la figura 17 se muestra también el porcentaje de cobertura total de un punto de cambio

identificado como función del porcentaje de datos faltantes, método de interpolación usado y valor de h. Se muestra que para ambos casos mientras el porcentaje de datos faltantes aumenta el porcentaje de la identificación de un punto de cambio disminuye, siendo el método spline con el que el algoritmo identifica mejor un punto de cambio.

En la figura 16 en la que el valor de h es fijo y el ruido cambia se observa que el mayor porcentaje de identificación de un punto de cambio es del 70.5% con un nivel de ruido=0.02. Se puede ver también que cuando el porcentaje de datos faltantes es del 40%, el porcentaje de identificación de un punto de cambio es mayor en comparación con porcentajes de datos faltantes mayores. En todos los casos se puede apreciar que el método de interpolación spline es el que contiene los mayores porcentajes de detección de un punto de cambio.




Figura 16. Gráfica del porcentaje de cobertura total de identificación de un punto de cambio (σ cambia) Método de interpolación: Spline Lineal

Mientras que en la figura 17 en la que el ruido es fijo y el valor de h cambia se observa que el mejor caso en el que el algoritmo identificó un punto de cambio es con un valor de $h=0.45$ y usando cualquiera de los dos métodos de interpolación. Para los otros valores de h el mejor método de interpolación es el spline.




Figura 17. Gráfica del porcentaje de cobertura total de identificación de un punto de cambio (h cambia) Método de interpolación: Spline Lineal

Cabe resaltar que, en las gráficas anteriores a pesar de tener un porcentaje alto de identificación de un punto de cambio, sólo se tomó en cuenta la identificación de un punto de cambio más no su correcta posición. Por lo cual, se calculó el porcentaje de cobertura de un punto de cambio correctamente identificado ilustrado en las figuras 18 (caso 1) y 19 (caso 2), en las que podemos observar que al igual que en las figuras anteriores, mientras el porcentaje de datos faltantes aumenta, el porcentaje de identificación correcta del punto de cambio disminuye, siendo ahora el método de interpolación lineal con los porcentajes más altos de identificación correcta en la mayoría de los casos.

Es importante recalcar que el porcentaje promedio de identificación correcta de un punto de cambio para el caso 1 en el que el valor de h es fijo ($h=0.15$) y el ruido varía es del 47.73% y para el caso 2 en el que el valor de h cambia es del 51.8% cuando se usó el método de interpolación lineal, mientras que cuando se usó interpolación spline este porcentaje disminuye. Lo cual sugiere que el algoritmo identifica mejor el punto de cambio correcto con el método de interpolación lineal, sin agregar tanto sesgo en la serie NDVI.

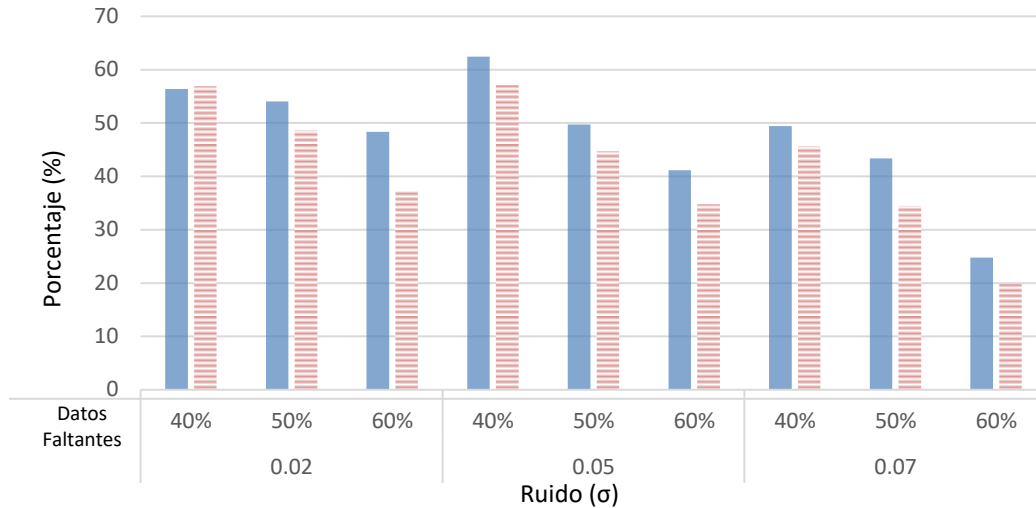


Figura 18. Gráfica del porcentaje total de un punto de cambio correctamente identificado con diferentes valores de σ (caso 1) Método de interpolación: ■ Lineal ■ Spline




Figura 19. Gráfica del porcentaje total de un punto de cambio correctamente identificado con diferentes valores de h (caso 2) Método de interpolación: ■ Lineal ■ Spline

La precisión de BFAST para estimar el número de cambios abruptos se presenta en la Figura 20; se usó el MSE para medir esta precisión. En general, se ilustra que el MSE es pequeño cuando el porcentaje de datos faltantes es bajo, el valor de $h=0.15$ y el nivel de ruido también es bajo. El MSE aumenta lentamente al aumentar los niveles de ruido y porcentaje de datos faltantes, cuando se trata del método de interpolación lineal. Mientras que cuando se trata del método de interpolación spline el MSE aumenta drásticamente al aumentar el porcentaje de datos faltantes y nivel de ruido.

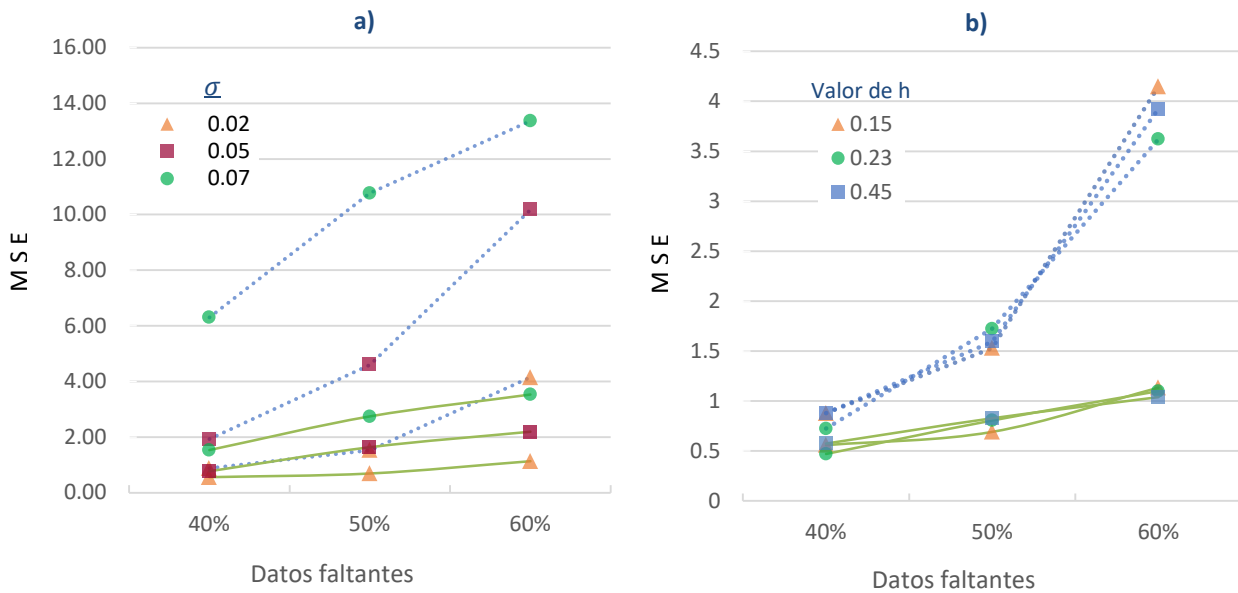


Figura 20. Gráfica de la precisión de BFAST para estimar el número de cambios abruptos usando el MSE
 a) El valor de h es constante y el nivel de ruido (σ) cambia, b) el nivel de ruido (σ) es constante y el valor de h cambia
 Método de interpolación: — Lineal Spline

4.3.2 Identificación de dos puntos de cambio

En esta simulación se muestran los resultados sólo para dos valores de h ($h=0.15$ y $h=0.23$). Para el caso de $h=0.45$ no se presentan resultados debido a que solo detectó un punto de cambio para todas las distancias. Lo anterior es debido a que cuando h es más grande se necesita una distancia mucho mayor para que identifique dos puntos de cambio. Por lo tanto, es necesario tener una serie de tiempo mucho más larga. En las figuras 21 y 22 se muestra el porcentaje de dos puntos de cambio correctamente identificados.

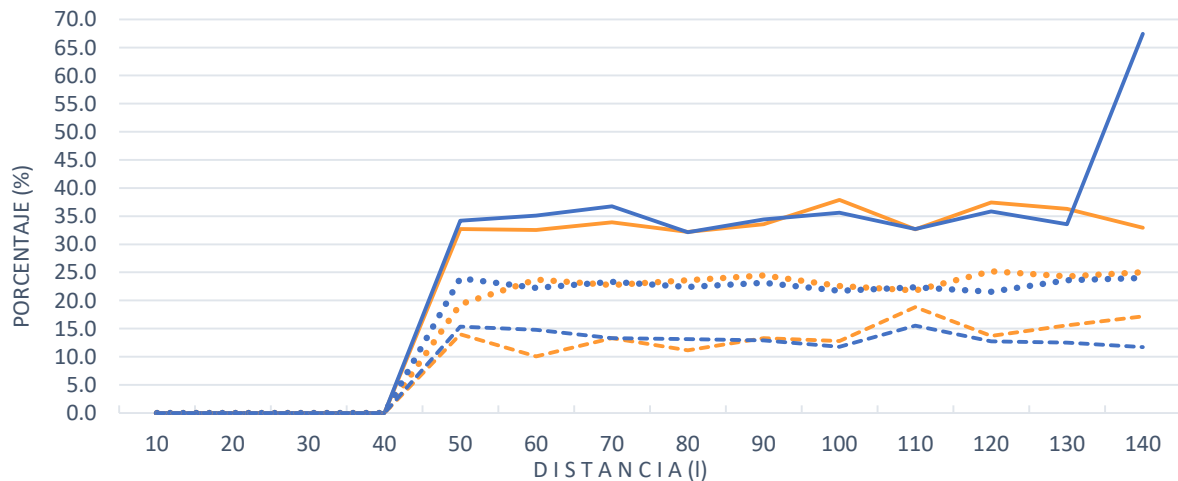


Figura 21. Gráfica del porcentaje total de dos puntos de cambio correctamente identificados con $h=0.15$
 Datos Faltantes: — 40% 50% - - - - 60% Método de interpolación: ■ Lineal ■ Spline

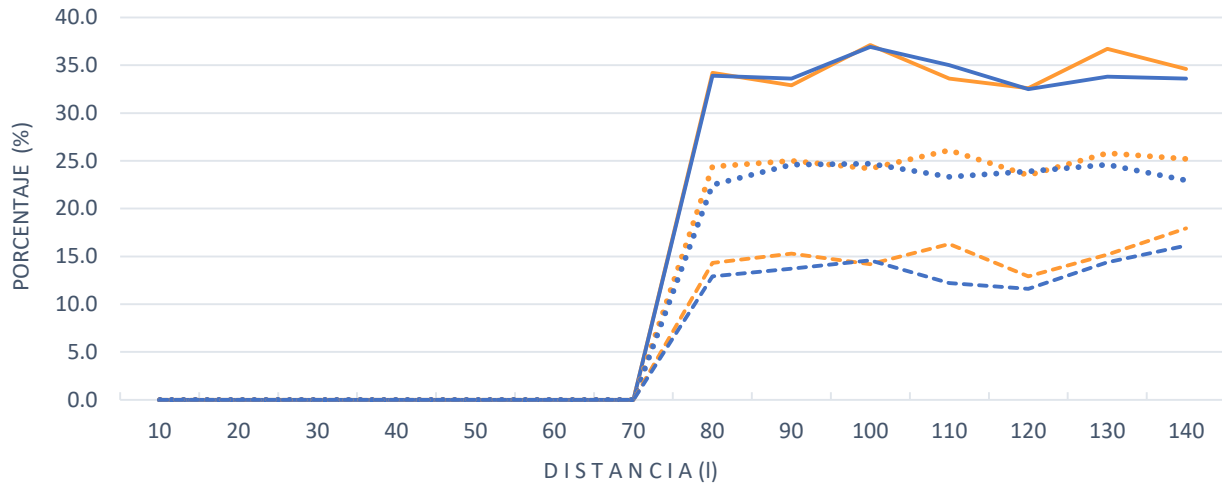


Figura 22. Gráfica del porcentaje total de dos puntos de cambio correctamente identificados con $h=0.23$

Datos Faltantes: — 40% 50% - - - - 60% Método de interpolación: ■ Lineal ■ Spline

Para el caso $h=0.15$ los puntos de cambio correctos empiezan a detectarse a partir de la distancia $l=50$ (aproximadamente a partir de 2 años). Siendo el método de interpolación spline el que mejor detecta los dos puntos de cambio correctos con un porcentaje promedio del 34.2% solo cuando existe el 40% de datos faltantes. Sin embargo, se puede ver también que conforme el porcentaje de datos faltantes aumenta el método de interpolación lineal es el que tiene el mayor porcentaje de detección de los dos puntos de cambio correctos. El método de interpolación spline es el que tiene altos porcentajes de sobreestimación y subestimación de puntos de cambio. La sobreestimación empieza a partir de la distancia $l=50$ hasta 140 y la subestimación solo en las primeras distancias $l=10, 20$ y 30 pero con porcentajes mucho más altos, estos se ilustran en las figuras 23 y 24 respectivamente.




Figura 23. Gráfica del porcentaje total de sobreestimación de puntos de cambio con $h=0.15$

Datos Faltantes: ■ 40% , ■ 50% v ■ 60%. Método de interpolación: ■ Lineal ■ Spline

En cambio, para el caso de $h=0.23$ la detección de los dos puntos de cambio correctos empieza a partir de la distancia $l=70$ (aproximadamente 3 años) pero ahora el método de interpolación lineal es el que mejor detecta los dos puntos de cambio correctos en todas las distancias y con diferentes porcentajes de datos faltantes. Para este caso no hay sobreestimación de puntos de cambio, pero sí subestimación de éstos a partir de las distancias $l=10$ hasta $l=50$ con porcentajes mayores al 40% de puntos subestimados (figura 25).

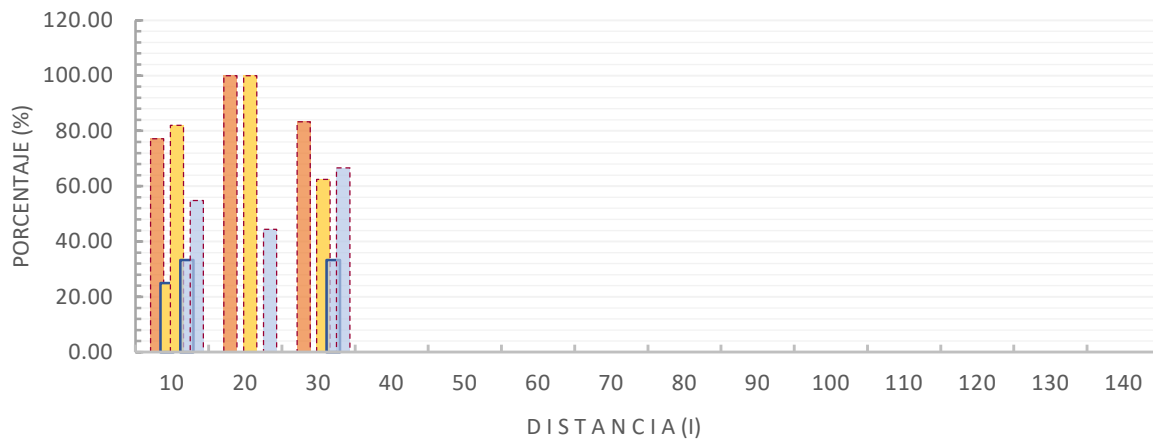


Figura 24. Gráfica del porcentaje total de subestimación de puntos de cambio con $h=0.15$

Datos Faltantes: 40%, 50%, 60% Método de interpolación: Lineal Spline




Figura 25. Gráfica del porcentaje total de subestimación de puntos de cambio con $h=0.23$

Datos Faltantes: 40%, 50%, 60% Método de interpolación: Lineal Spline

Por lo anterior, se deduce que con $h=0.15$ se subestima menos, pero se sobreestima más, y con $h=0.23$ no hay sobreestimación, pero sí hay un porcentaje alto de subestimación de puntos de cambio. Cuando la serie de tiempo está completa (sin datos faltantes), en los dos escenarios considerados en nuestras simulaciones, BFAST es robusto en la detección correcta de los puntos

de cambio, pero deja de serlo cuando hay cierto porcentaje de datos faltantes dentro de las series de tiempo. Por lo cual es recomendable que la serie de tiempo a utilizar como datos de entrada para la aplicación de BFAST tenga el menor porcentaje de datos faltantes posibles (menos del 40%) para que haya una correcta identificación de cambios.

4.4 APLICACIÓN ESPACIAL EN SERIES DE TIEMPO LANDSAT-7 (NDVI)

Con BFAST se encuentran cambios abruptos dependiendo del comportamiento de la serie. Si hay disminución o aumento estadísticamente significativos en los valores de la variable biofísica, entonces BFAST identifica los cambios abruptos mediante regresiones robustas. Es necesario mencionar que, de los cambios abruptos detectados aquí, no se puede saber de qué tipo de cambio se trata, ya que la detección es en general y puede haber cambios decrecientes como crecientes (tendencia negativa o positiva). En particular para asociar estos cambios con áreas afectadas por incendios se utilizó lo descrito en la sección 3.3.

La aplicación de BFAST a la serie temporal NDVI para la detección de cambios abruptos en la componente de tendencia, produjo estimaciones del tiempo (fecha) y la magnitud de los cambios principales. Dichos resultados se muestran en la figura 26. Los cambios estimados por BFAST se resumen a año para facilitar el análisis y comparación. Los parámetros utilizados para la aplicación de BFAST fueron, la serie de tiempo rellenada a través del método de interpolación lineal y dos valores de h ($h=0.15$ y $h=0.23$), debido a que estos parámetros presentaron los mejores resultados en las pruebas de simulación.

Los cambios abruptos detectados por año y para cada valor h se muestran en la tabla 7, en la que podemos corroborar de acuerdo a los estudios de simulación, que cuando se usó $h=0.15$ la detección de los cambios empieza a partir de aproximadamente 2 años y cuando se usó $h=0.23$ la detección de los cambios empieza aproximadamente a partir de 3 años, por lo cual en este caso los cambios empezaron a detectarse a partir del año 2005 para $h=0.15$ y a partir del 2006 para $h=0.23$, debido a que el inicio del periodo de estudio fue en 2003. De esto podemos deducir que utilizando un valor de h más grande tendrá que transcurrir un periodo de tiempo

más largo para que los cambios sean detectados. Se observa también que con un valor de $h=0.15$ se detectan más cambios en la mayoría de los años.

Tabla 7. Cambios abruptos detectados por año

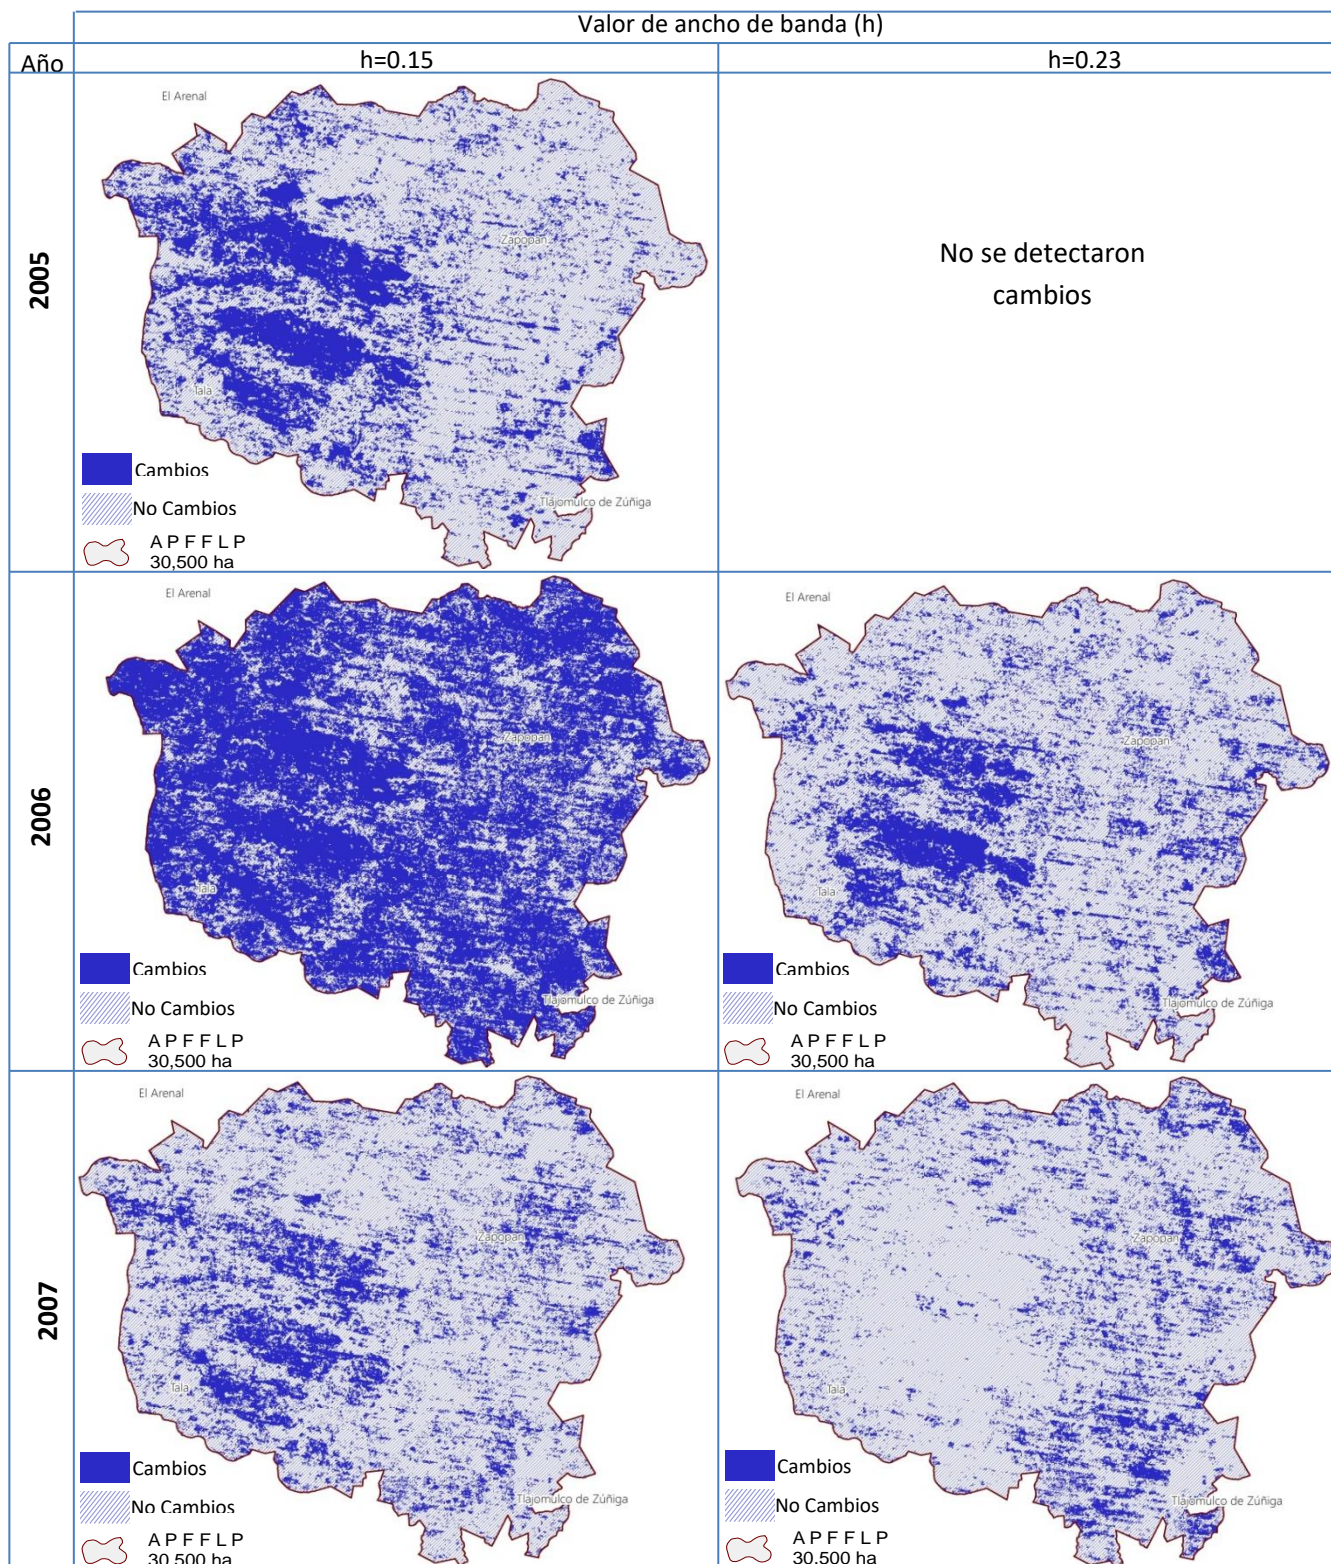


Tabla 7. Cambios abruptos detectados por año

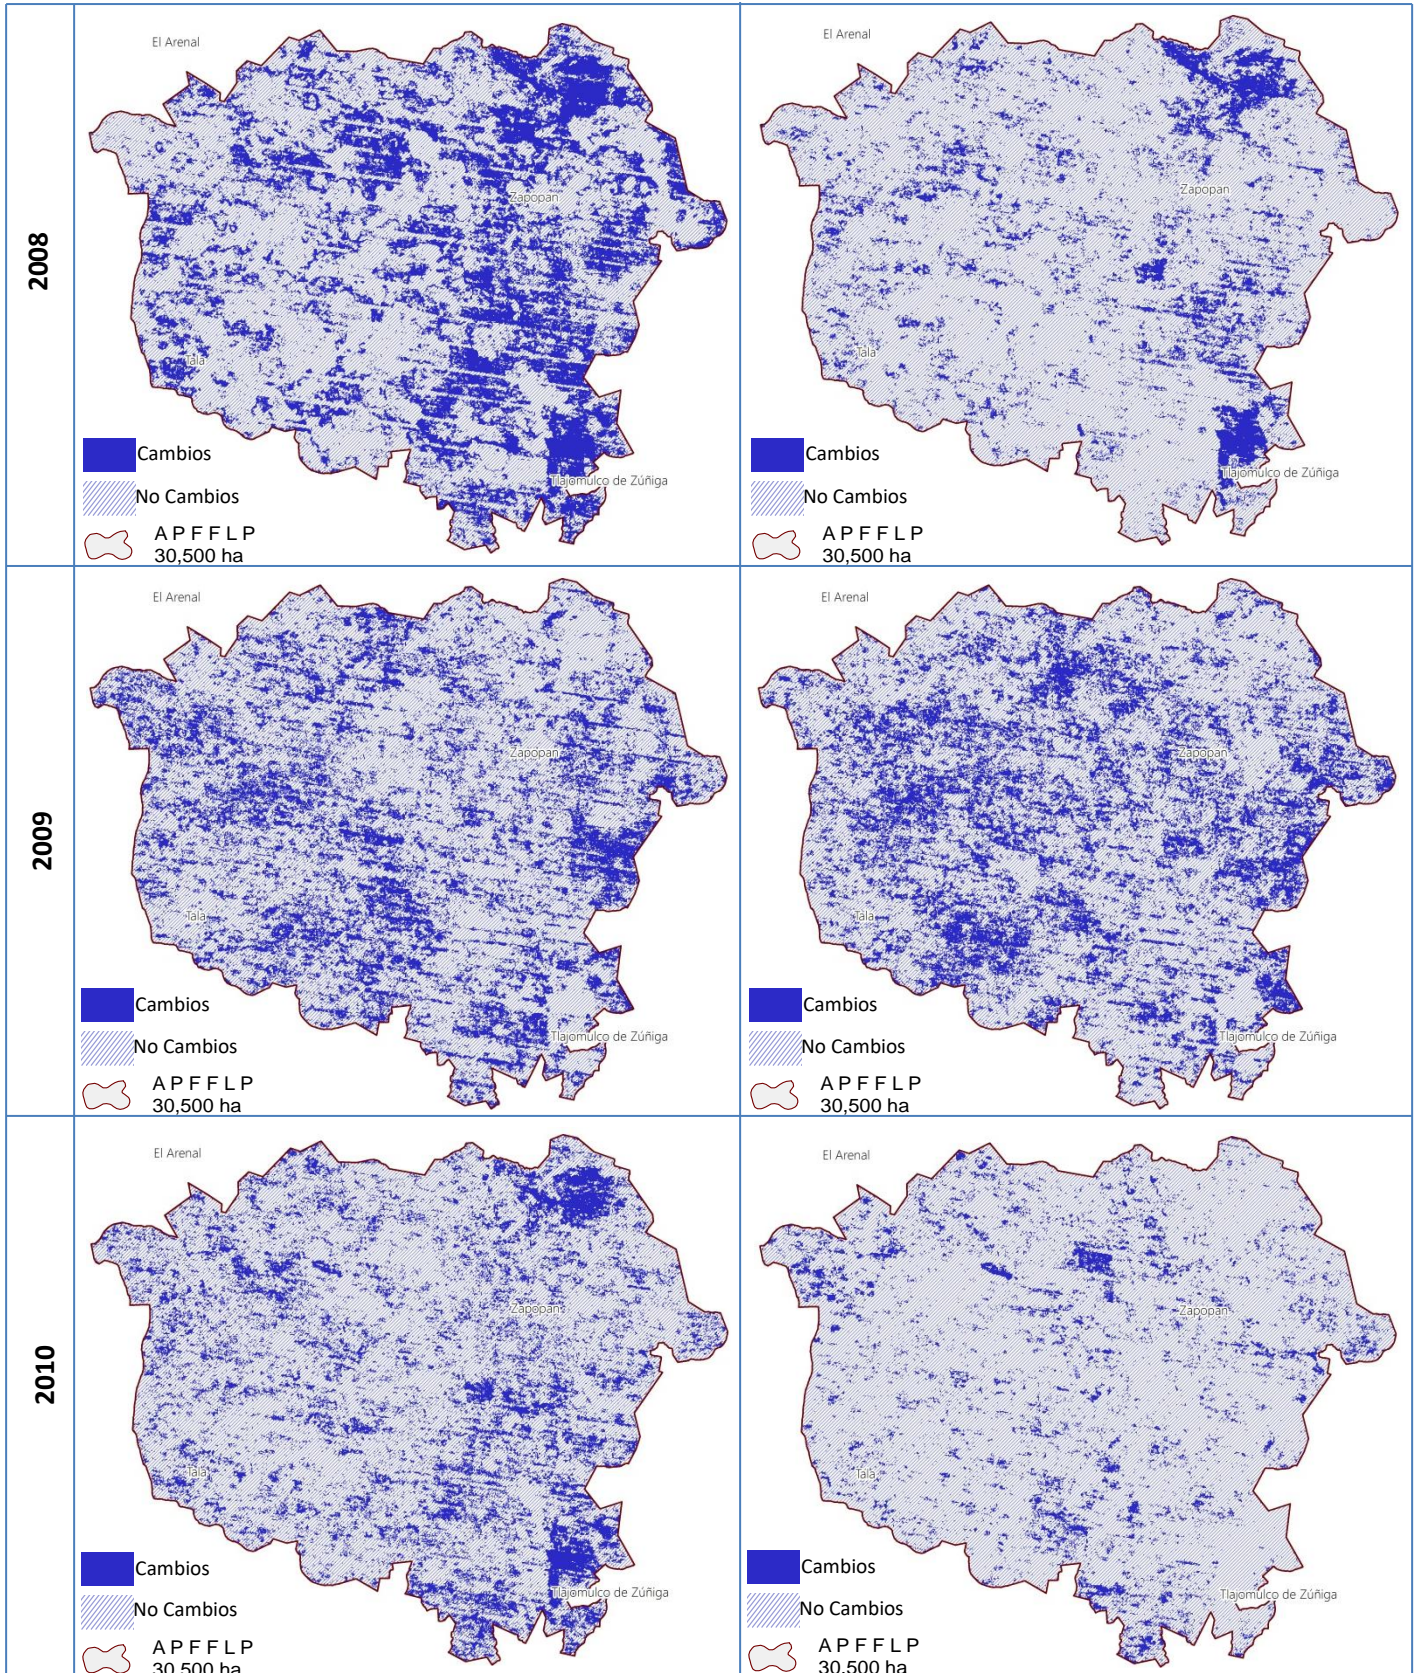


Tabla 7. Cambios abruptos detectados por año

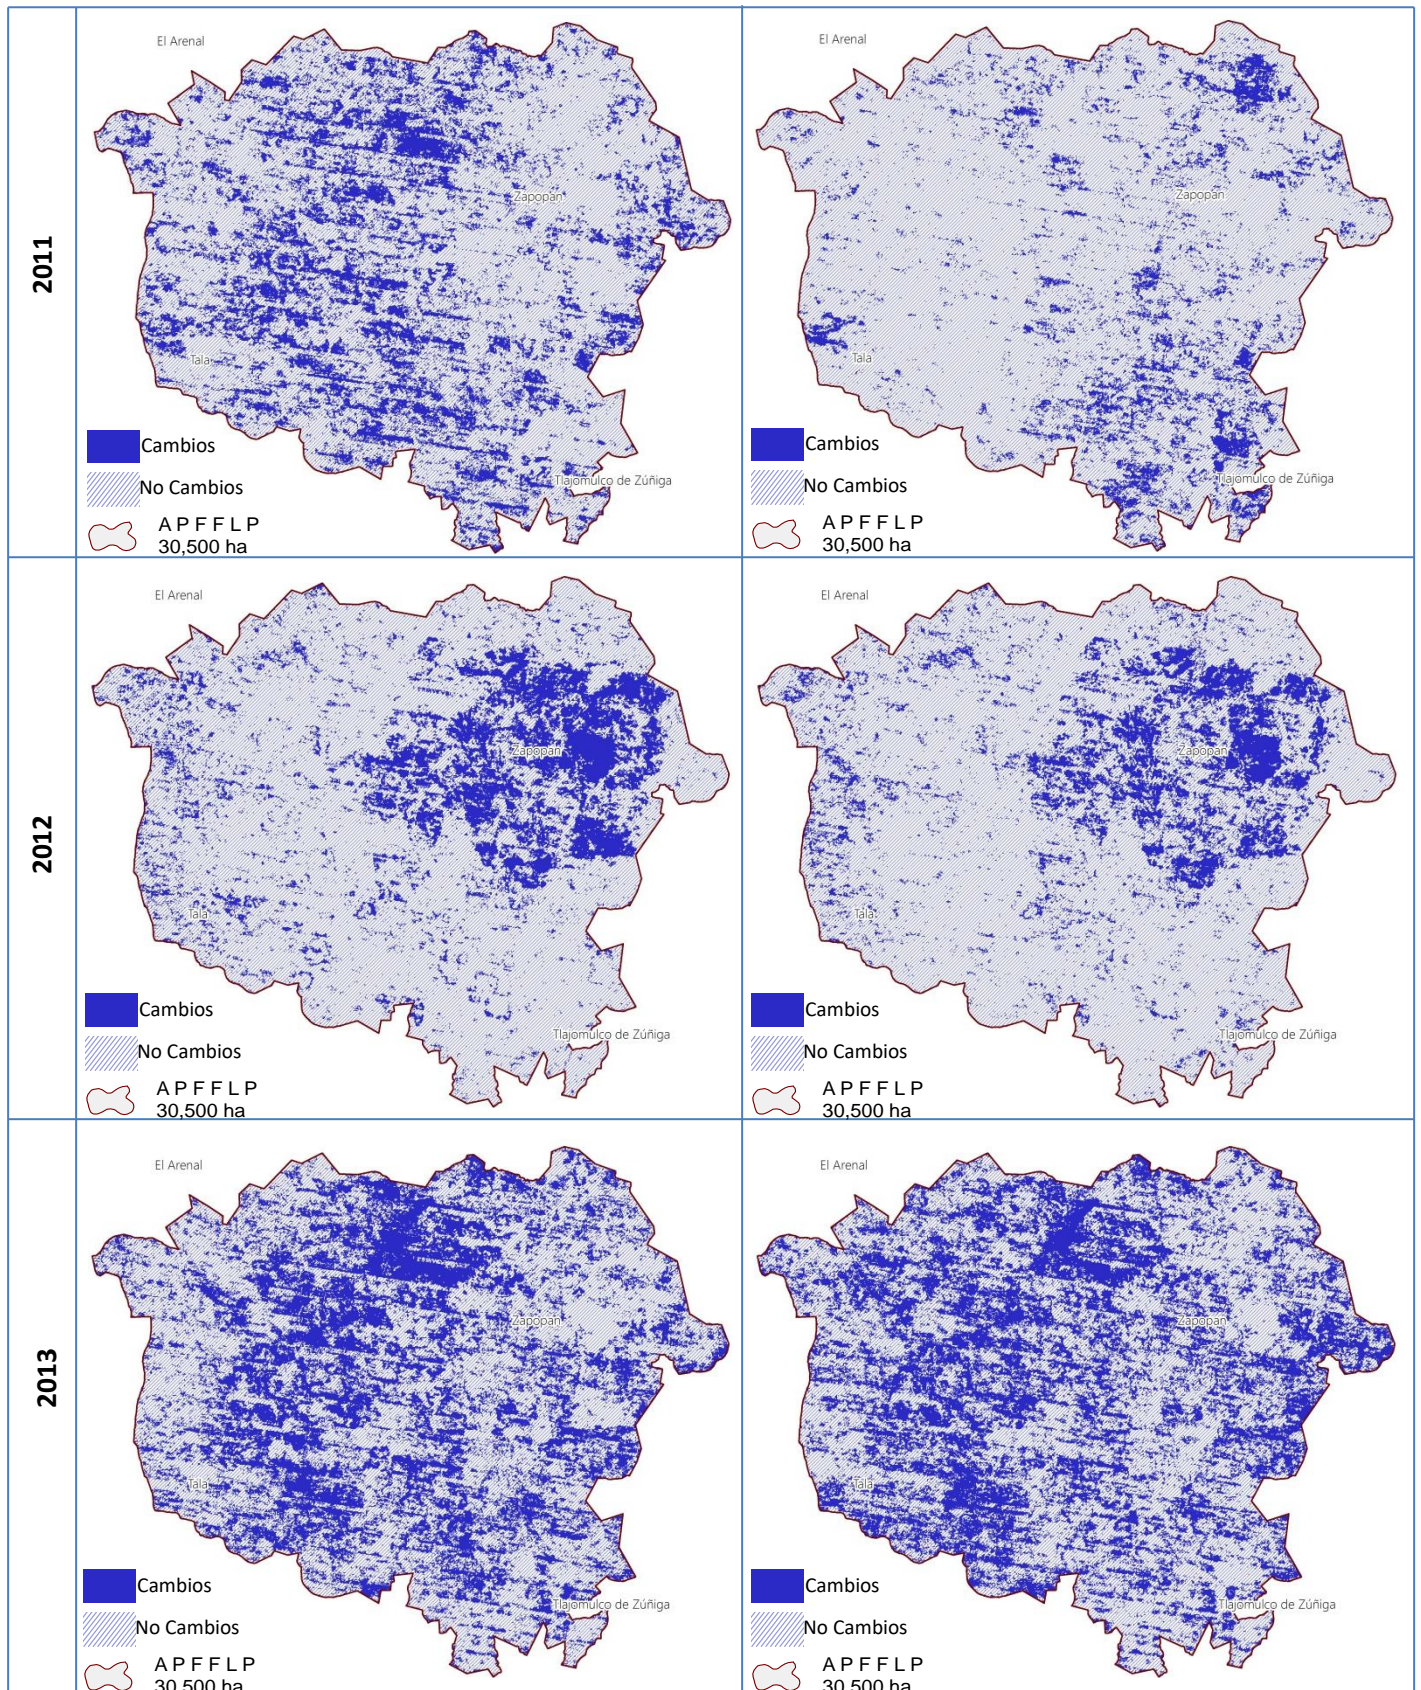
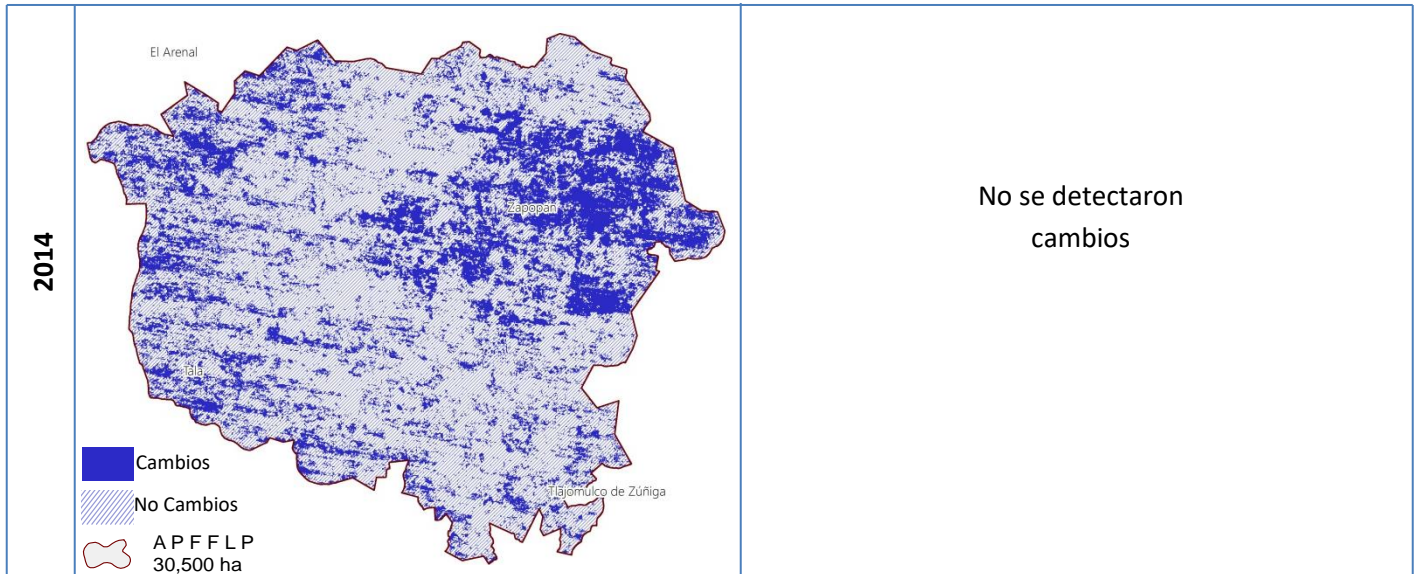


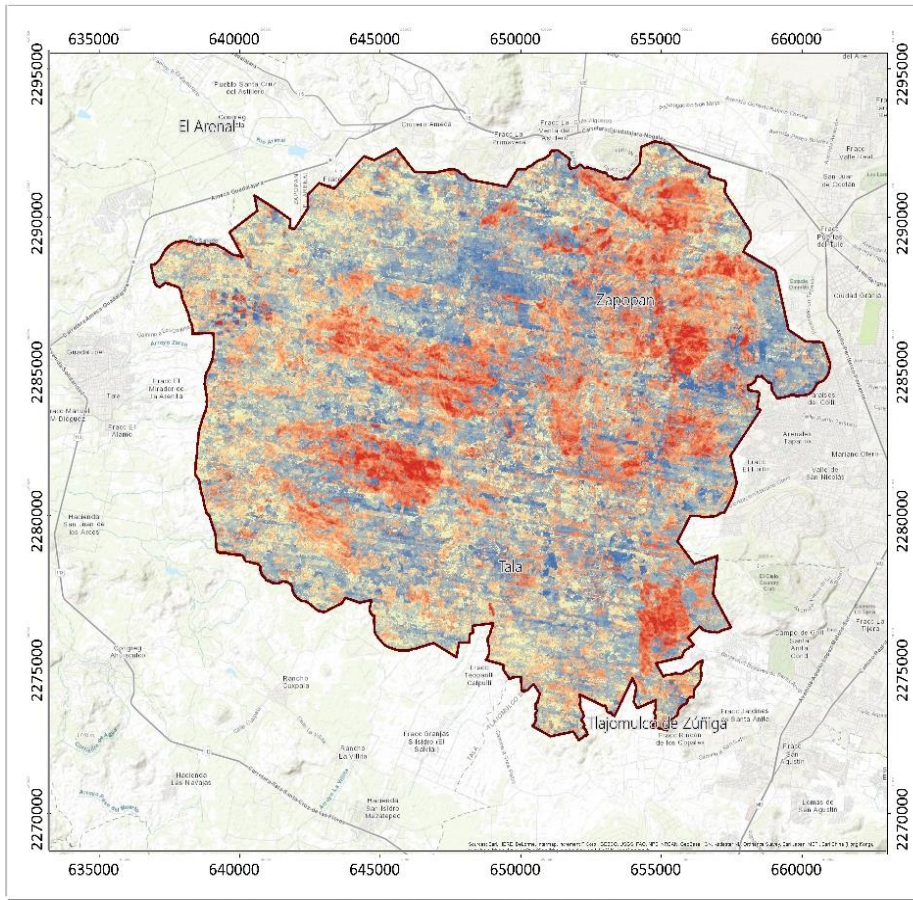
Tabla 7. Cambios abruptos detectados por año



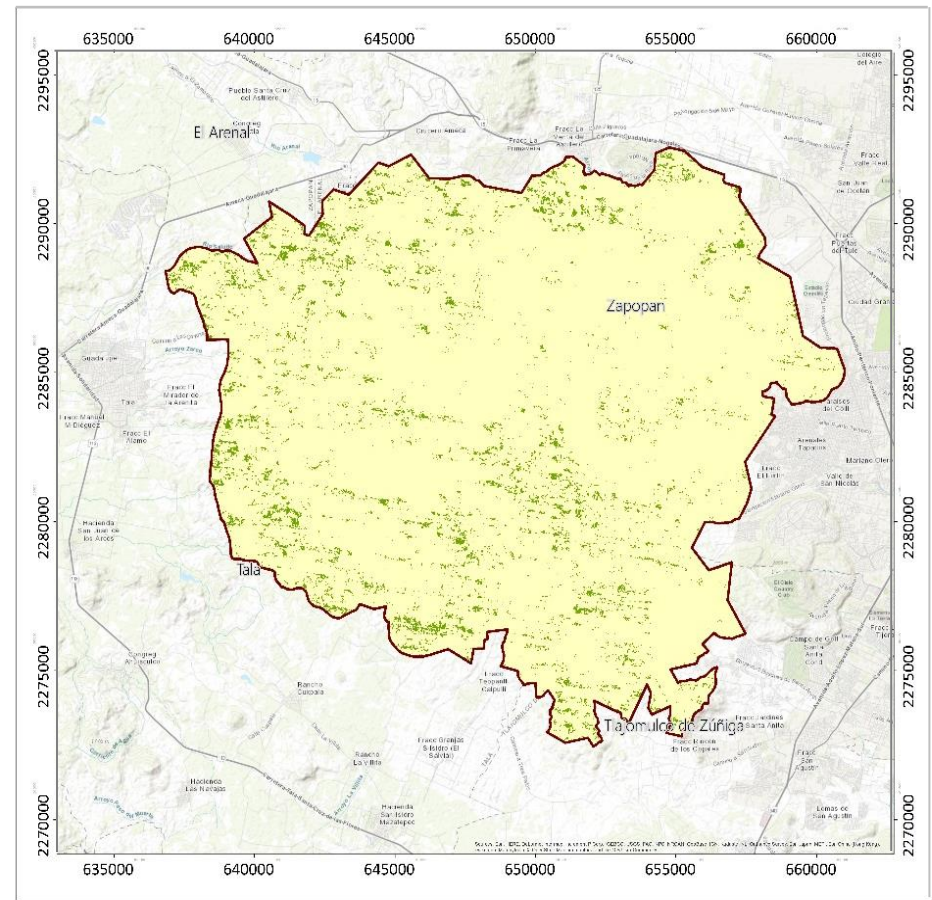
La figura 26(A) muestra que los cambios detectados pueden tener una magnitud de cambio negativa o positiva. Esto puede explicarse por el hecho de que la pérdida del bosque en el área de estudio corresponde a algún cambio y por lo tanto presenta una magnitud negativa, en el caso contrario cuándo hay recuperación o recrecimiento de la vegetación presenta una magnitud positiva.

En este caso los incendios o áreas quemadas causan una disminución significativa en el valor del NDVI, mientras que el crecimiento o recuperación de ésta provoca un aumento gradual del NDVI. Por ejemplo, el incendio que se produjo en el año 2008, la serie temporal de NDVI contenía una disminución significativa. Por lo tanto, BFAST detectó un cambio con una magnitud negativa en este año (Fig. 27).

Por otra parte, la figura 26(B) ilustra la sumatoria de los cambios y no cambios detectados en el periodo 2003-2016 en la que se puede observar que BFAST reporta más cambios significativos ($\alpha=0.05$) que no cambios en el NDVI del área de estudio. A la luz de estas imágenes se puede conjeturar que la mayoría de los cambios pueden ser atribuidos a incendios



(A) Magnitudes del cambio 2003-2016



(B) Cambios detectados 2003-2016




Figura 26. Mapa de cambios y magnitud del cambio

(A) Magnitudes estimadas por BFAST de los principales cambios detectados en (B) para el APFFLP, los valores negativos podrían asociarse con áreas quemadas y los valores positivos a la recuperación de la vegetación; (B) Estimación de BFAST de los principales cambios detectados en serie de tiempo NDVI (2003-2016) para el APFFLP. ELABORACIÓN PROPIA.




Figura 27. Cambios detectados en la componente de tendencia de la serie de tiempo NDVI de un pixel específico del área de estudio

Tendencia estimada (línea azul) de la serie de tiempo NDVI (línea gris). El intervalo de confianza (rojo) correspondiente al tiempo y magnitud entre puntos de cambio detectados. Los tres puntos de cambio detectados en 2006, 2008 y 2013 (círculos en rojo). El cambio del 2008 (línea punteada verde) relacionado con el incendio de la misma fecha.

La figura 28 ilustra los cambios detectados dentro de la serie temporal NDVI extraídos de un pixel Landsat-7 con 30% de NA's. Se observa que hay una disminución significativa del NDVI causada por un incendio ocurrido en 2013 (dato de campo proporcionado por la CONABIO) y por lo tanto tiene una magnitud negativa alta. El ejemplo muestra como BFAST estimó correctamente el punto cambio en el tiempo y componente de tendencia para dicho año.

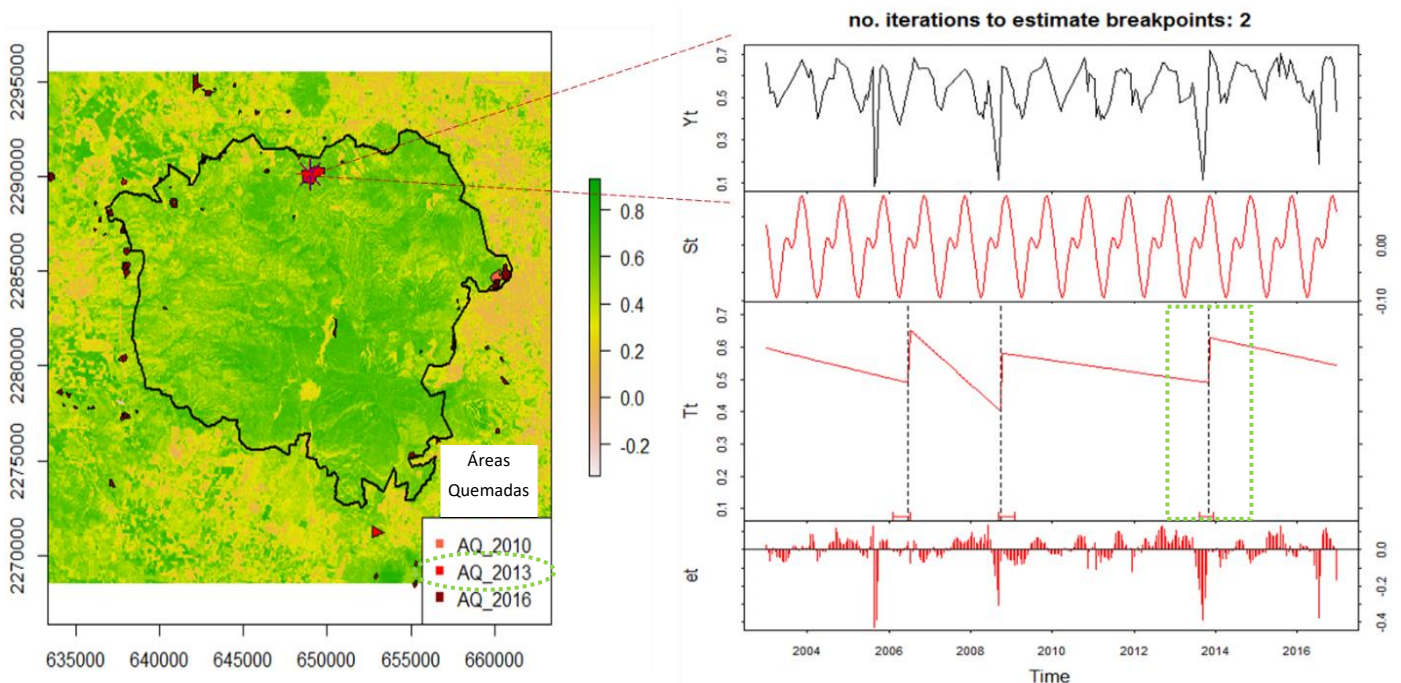


Figura 28. Detección del punto de cambio del 2013 en series de tiempo NDVI con 30% de NA's
Cambio abrupto detectado en 2013 con BFAST (línea punteada verde).

El punto anterior mostró la capacidad de BFAST para detectar y caracterizar el cambio a pesar de tener cierto porcentaje de datos faltantes, pero también confirmó la importancia de simular series de tiempo en un entorno controlado, ya que resulta difícil encontrar datos para validar y dar cuenta de todos los tipos de cambio que ocurren en los diferentes ecosistemas (Verbesselt *et al.*, 2009).

Por otra parte, en la figura 29 se muestran los cambios detectados en la serie de tiempo NDVI para un pixel donde existe una sobreposición entre los incendios ocurridos en 2005 y 2013, en la cual podemos observar que el NDVI disminuyó significativamente con una magnitud negativa, en los que la posible recuperación o crecimiento de la vegetación en 2005 es más lenta con una pendiente gradual en comparación con el cambio detectado en 2013, esto puede ser debido a que el incendio ocurrido en 2005 presentó un nivel de severidad media-alta (ver sección 4.5).




Figura 29. Tendencia estimada de la serie de tiempo NDVI. Pixel de áreas quemadas en 2005 y 2013

Tendencia estimada (línea azul) de la serie de tiempo NDVI (línea gris). El intervalo de confianza (rojo) correspondiente al tiempo y magnitud entre puntos de cambio detectados. Los círculos rojos indican los cuatro puntos de cambio detectados. Cambios abruptos detectados en 2005 y 2013 (línea punteada verde)

En 2005 y 2012, se presentaron dos grandes incendios que afectaron gran parte del área de estudio. Provocando que el NDVI disminuyera significativamente debido a que la vegetación quedó calcinada. Esto explica por qué los cambios detectados en 2005 y 2012 son mayores y la posible recuperación o crecimiento de la vegetación en 2012 es más lenta con una pendiente

gradual en comparación con el cambio detectado en 2005, ya que la pendiente después de 2012 es positiva mientras que la pendiente después de 2005 es negativa, como se puede observar en la figura 30. Este ejemplo ilustra cómo el método puede ser utilizado para detectar y caracterizar los cambios relacionados con el estado de la vegetación, así como su posible recrecimiento o recuperación después de un evento extremo.




Figura 30. Tendencia estimada de la serie de tiempo NDVI. Pixel de áreas quemadas en 2005 y 2012

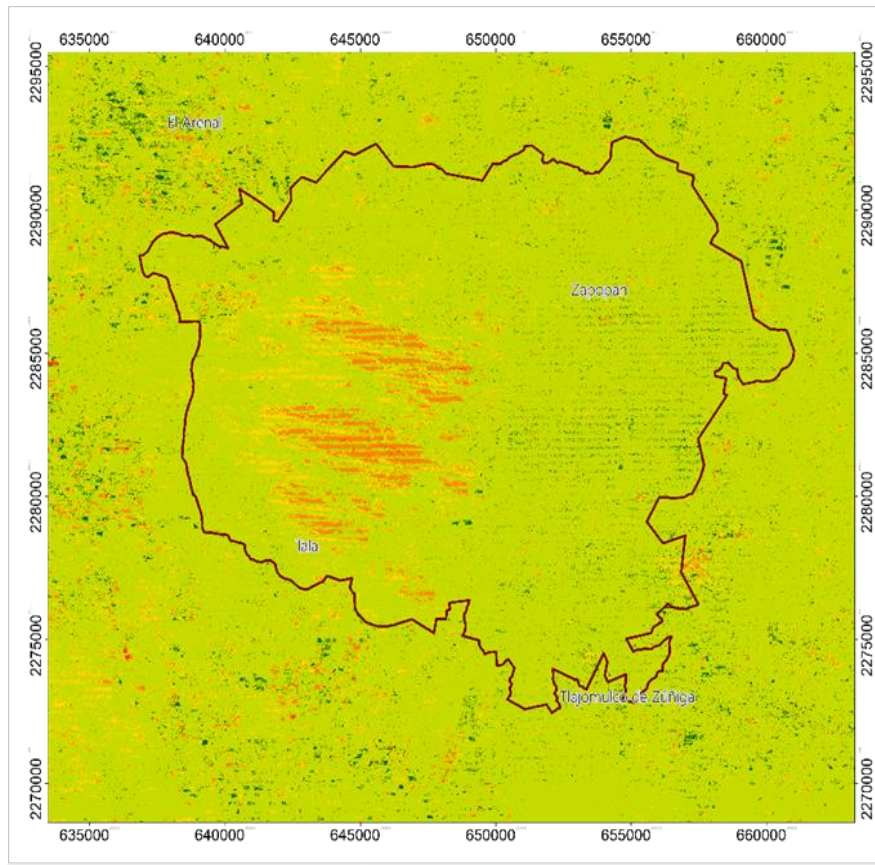
Tendencia estimada (línea azul) de la serie de tiempo NDVI (línea gris). El intervalo de confianza (rojo) correspondiente al tiempo y magnitud entre puntos de cambio detectados. Los círculos rojos indican los cambios abruptos detectados en 2005 y 2012 (línea punteada verde).

4.5 PROXY- SEVERIDAD DE LAS ÁREAS QUEMADAS DETECTADAS

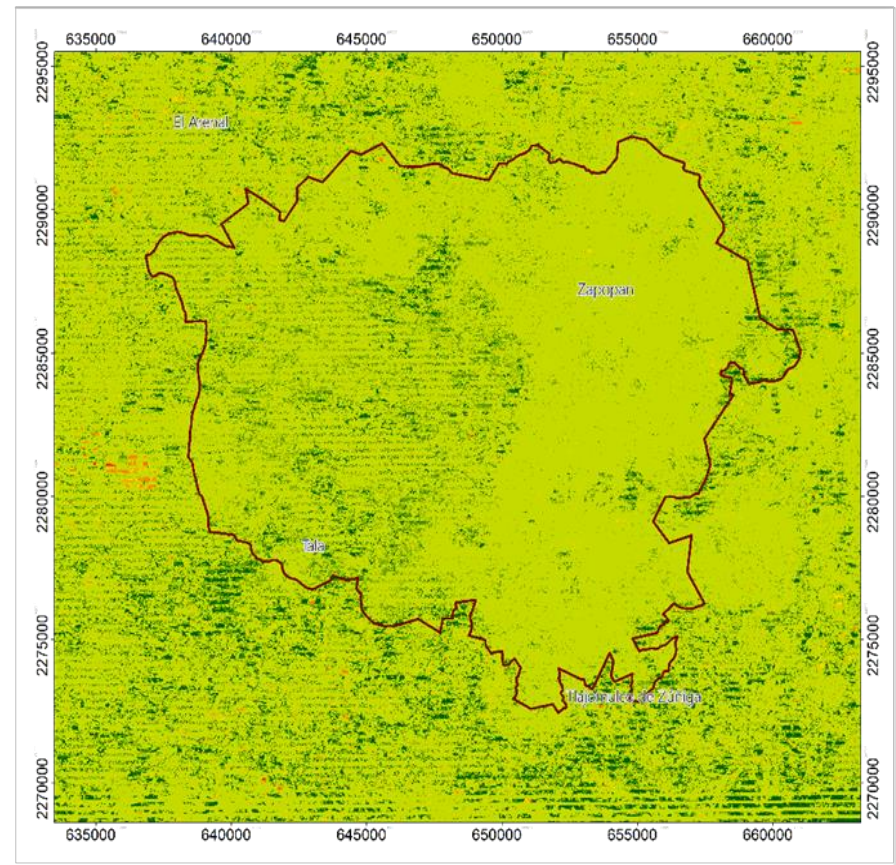
La cuantificación de la severidad de la quema usualmente se emplea para referirse al nivel de daño o perturbación causada por el fuego en el ecosistema (Key & Benson, 2006), es decir, un descriptor del impacto del fuego sobre la vegetación.

En las figuras de la 31 a la 35 y 36 a la 39 se ilustran las áreas quemadas detectadas y el grado de severidad de éstas para el valor de $h=0.15$ y $h=0.23$ respectivamente del APFFLP correspondientes al periodo 2003-2016, con base a la clasificación descrita en la sección 3.1.3.1 (iii).

Proxy-severidad de la quema



(a) dNBR - 2005



(b) dNBR - 2006

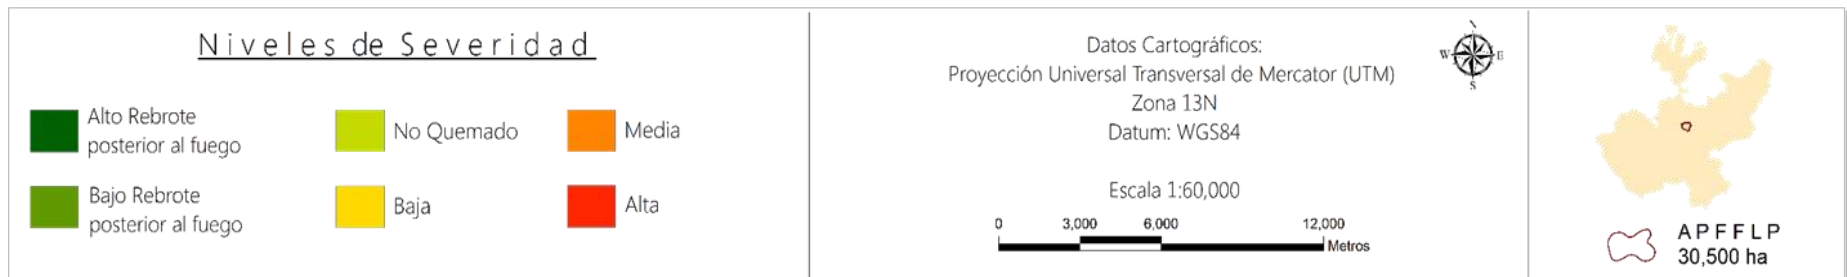
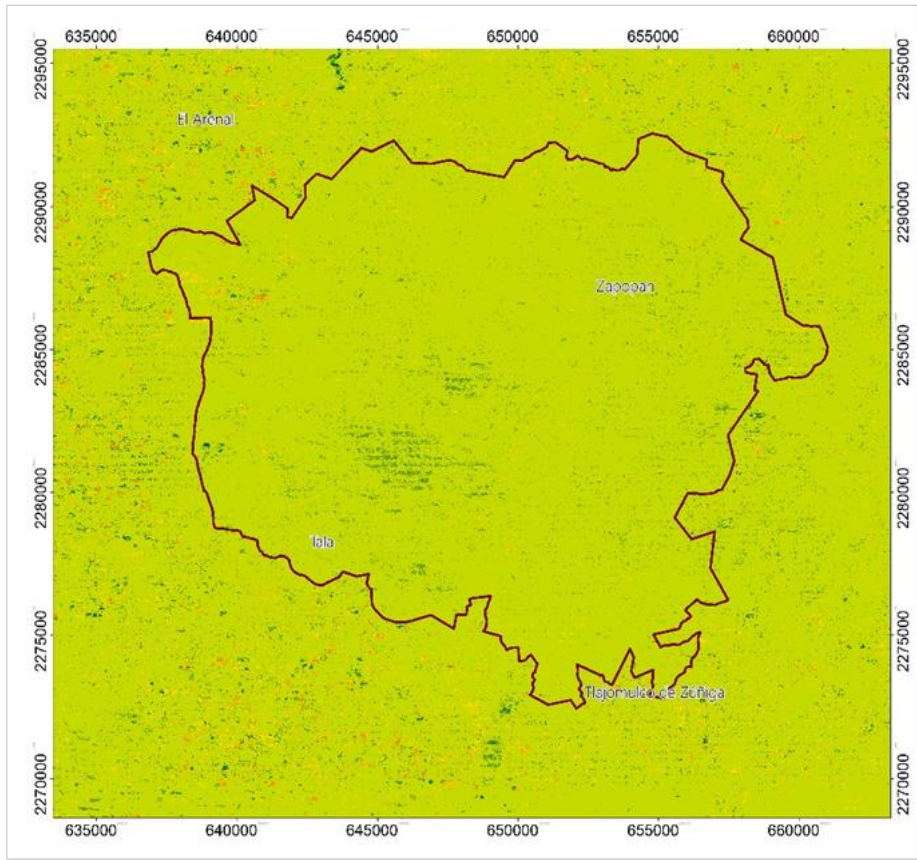


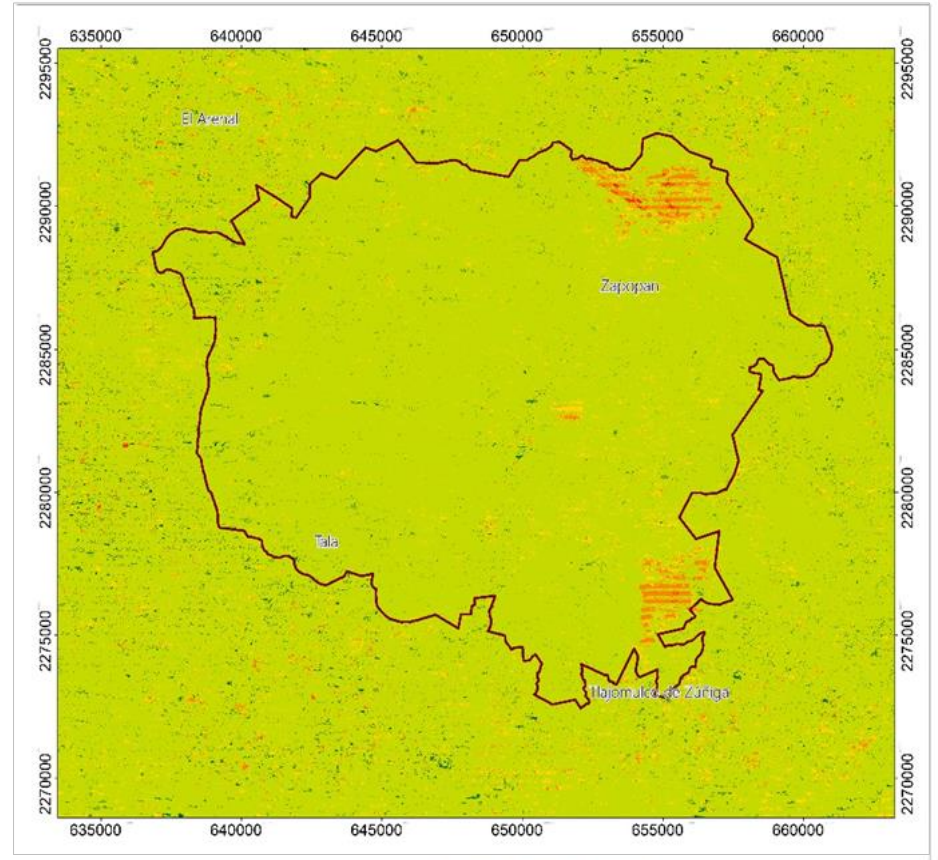
Figura 31. Mapas de proxy-severidad de la quema basados en ΔNBR 2005 y 2006, $h=0.15$

(a) dNBR 2005; (b) dNBR 2006. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Bajo rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(c) dNBR - 2007



(d) dNBR - 2008


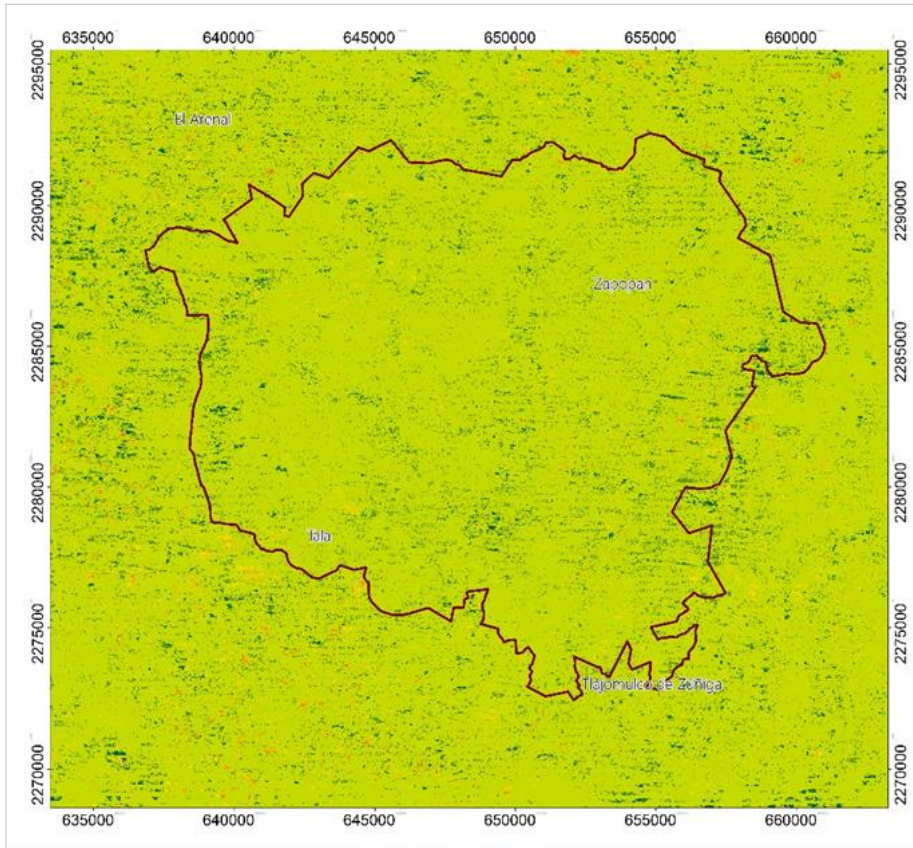


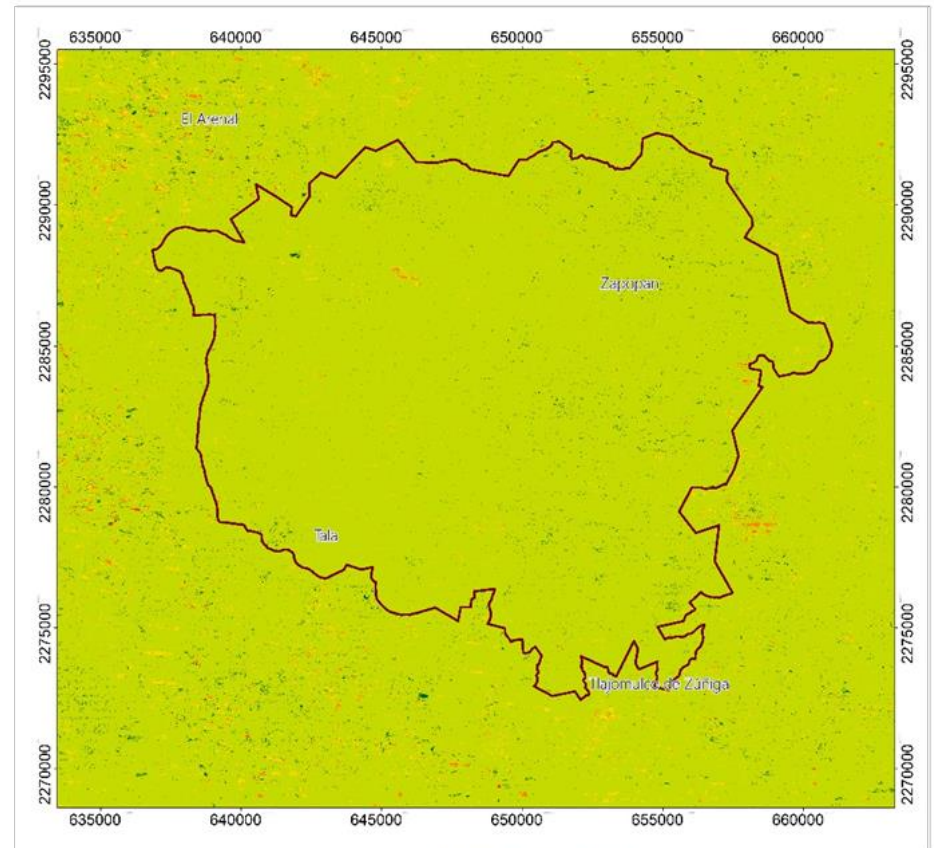
Figura 32. Mapas de proxy-severidad de la quema basados en ΔNBR 2007 y 2008, $h=0.15$

(c) dNBR 2007; (d) dNBR 2008. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(e) dNBR - 2009



(f) dNBR - 2010


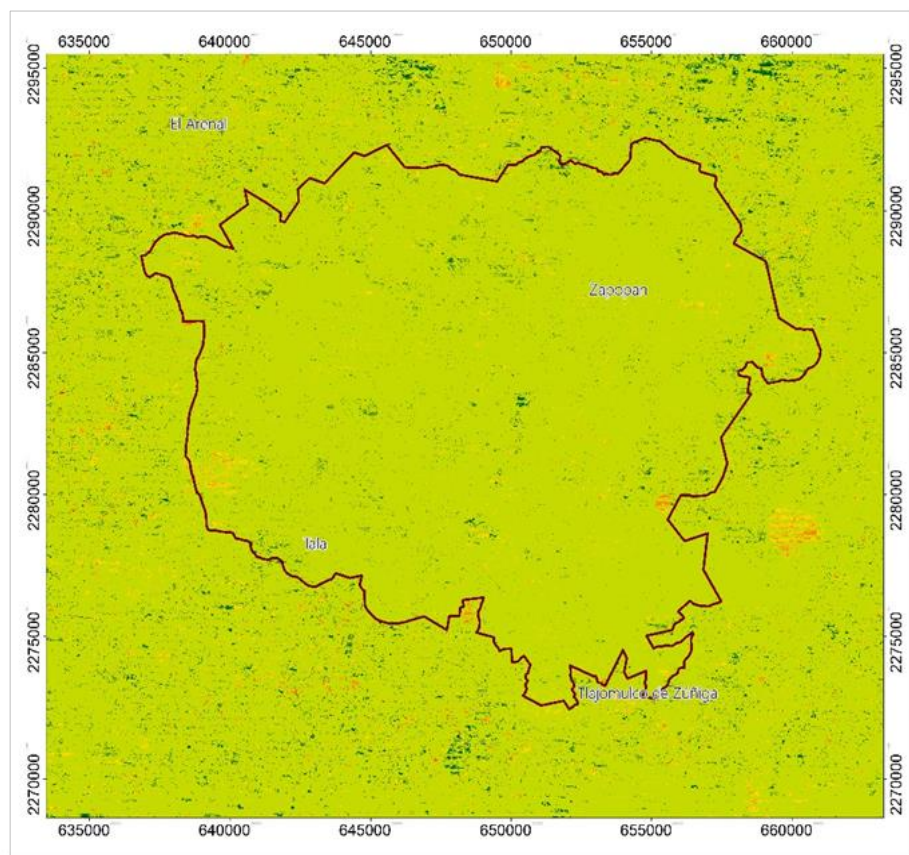


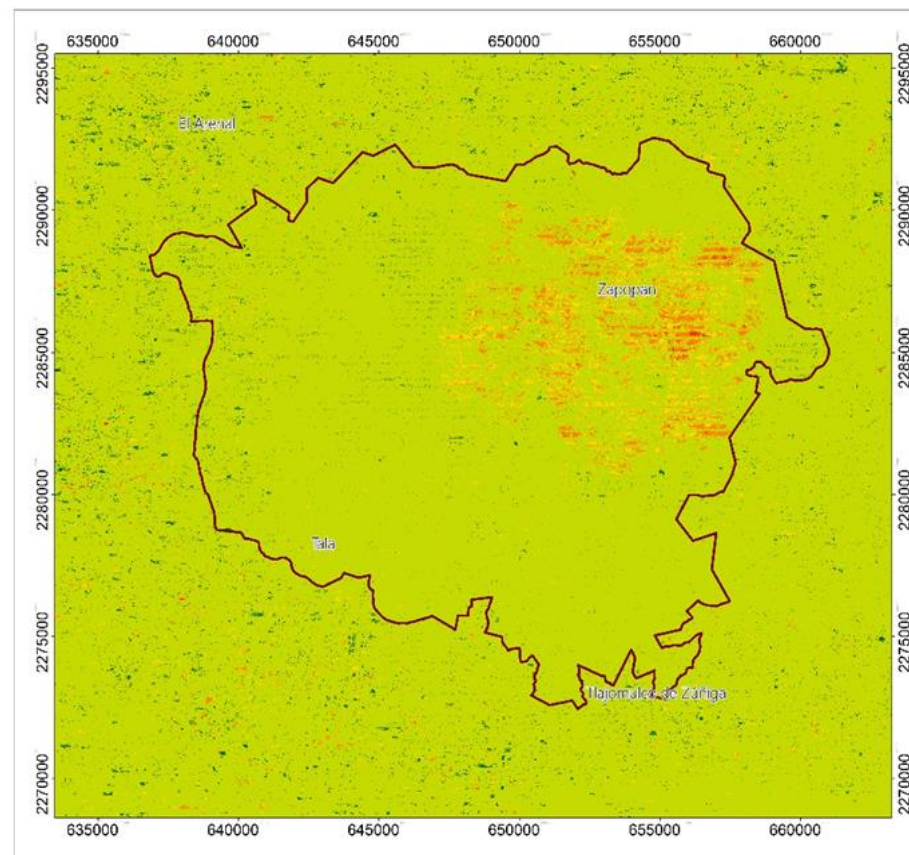
Figura 33. Mapas de proxy-severidad de la quema basados en ΔNBR 2009 y 2010, $h=0.15$

(e) dNBR 2009; (f) dNBR 2010. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(g) dNBR - 2011



(h) dNBR - 2012


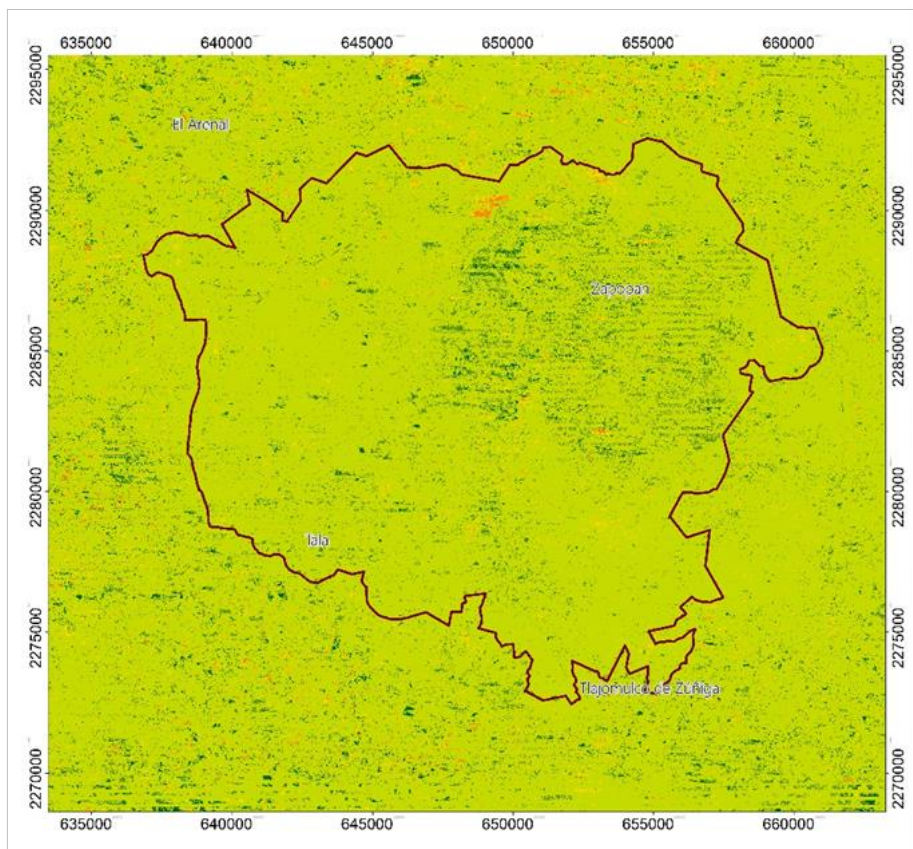


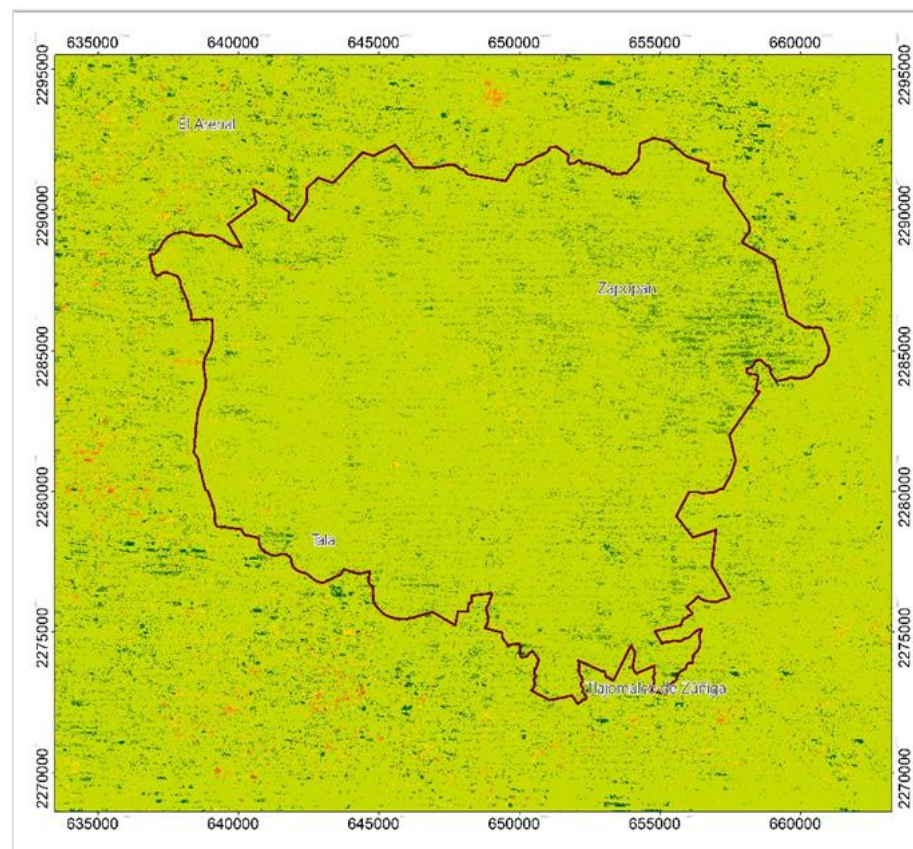
Figura 34. Mapas de proxy-severidad de la quema basados en ΔNBR 2011 y 2012, $h=0.15$

(g) dNBR 2011; (h) dNBR 2012. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(i) dNBR - 2013



(j) dNBR - 2014


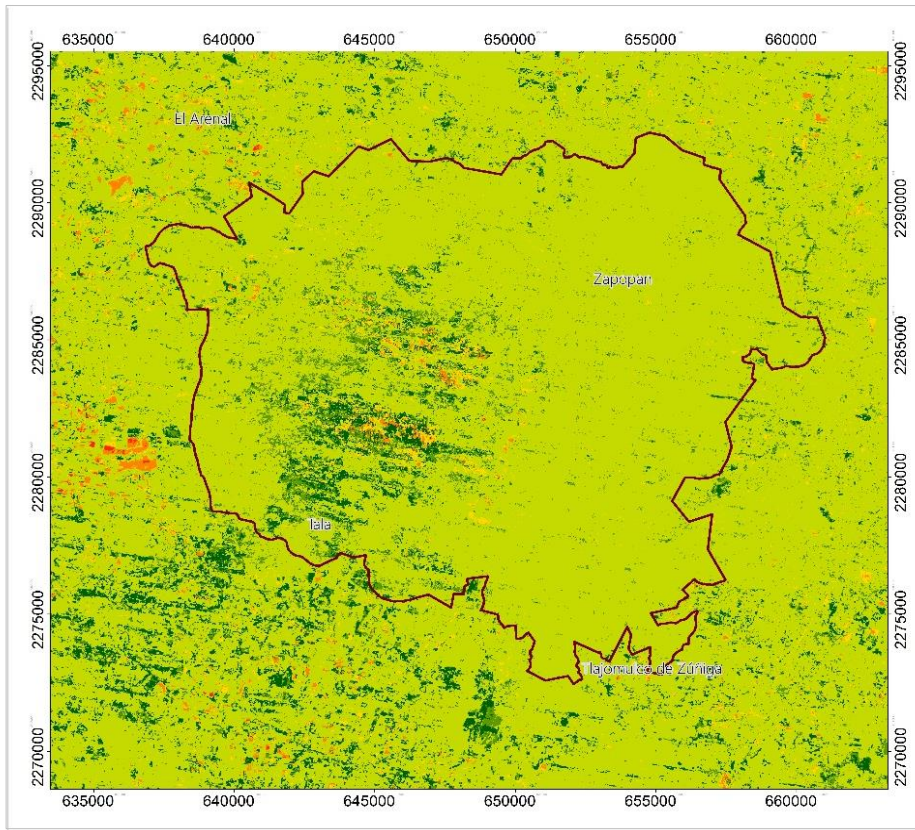


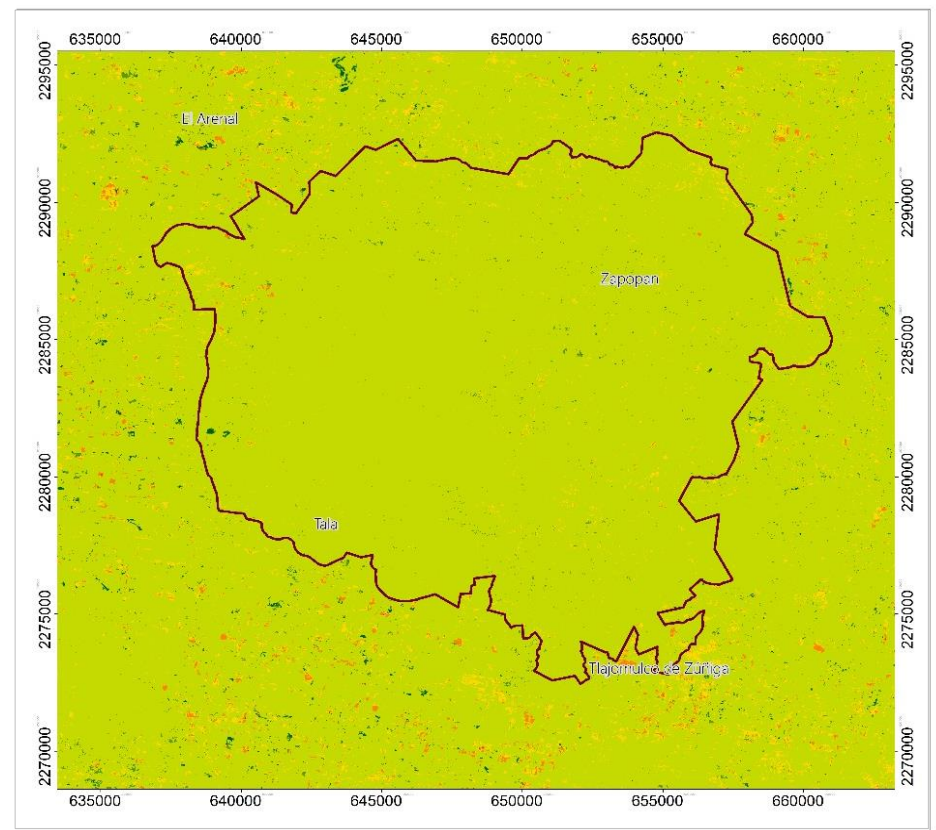
Figura 35. Mapas de proxy-severidad de la quema basados en ΔNBR 2013 y 2014, $h=0.15$

(i) dNBR 2013; (j) dNBR 2014. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(k) dNBR - 2006



(l) dNBR - 2007


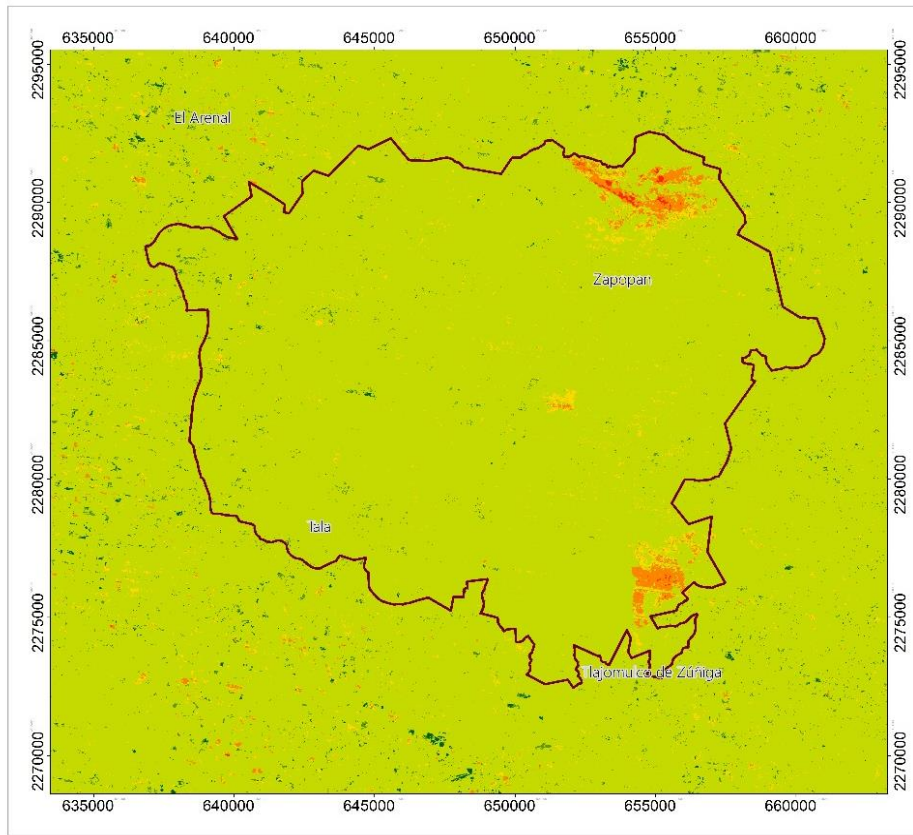


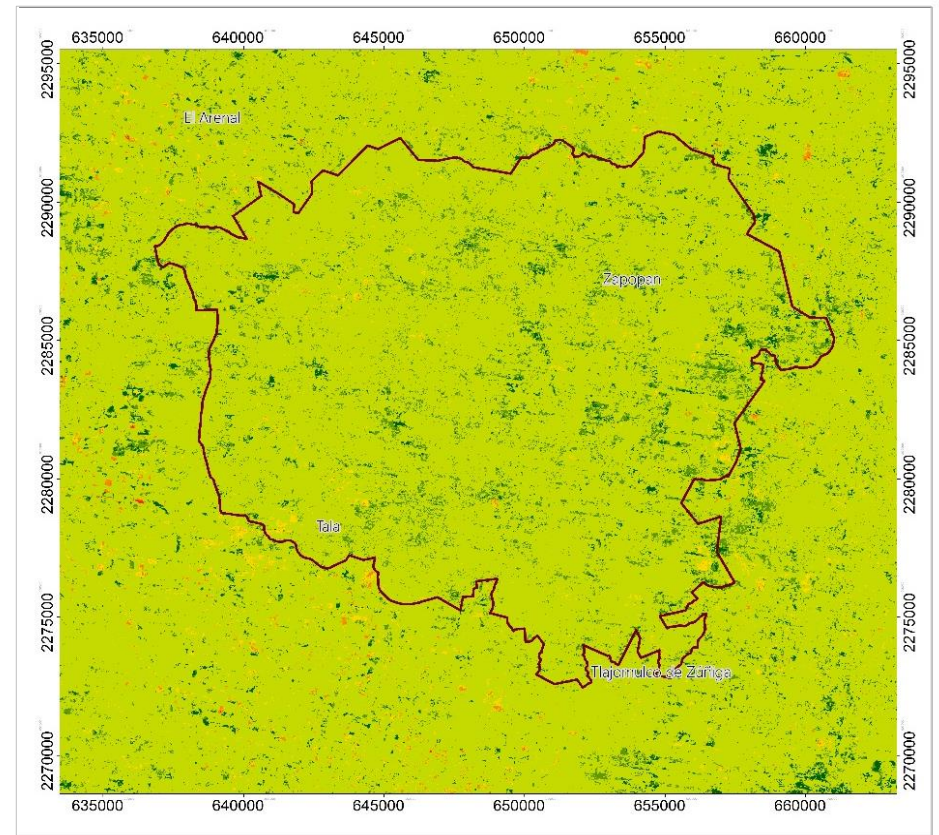
Figura 36. Mapas de proxy-severidad de la quema basados en ΔNBR 2006 y 2007, $h=0.23$

(k) dNBR 2006; (l) dNBR 2007. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66,]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(m) dNBR - 2008



(n) dNBR - 2009


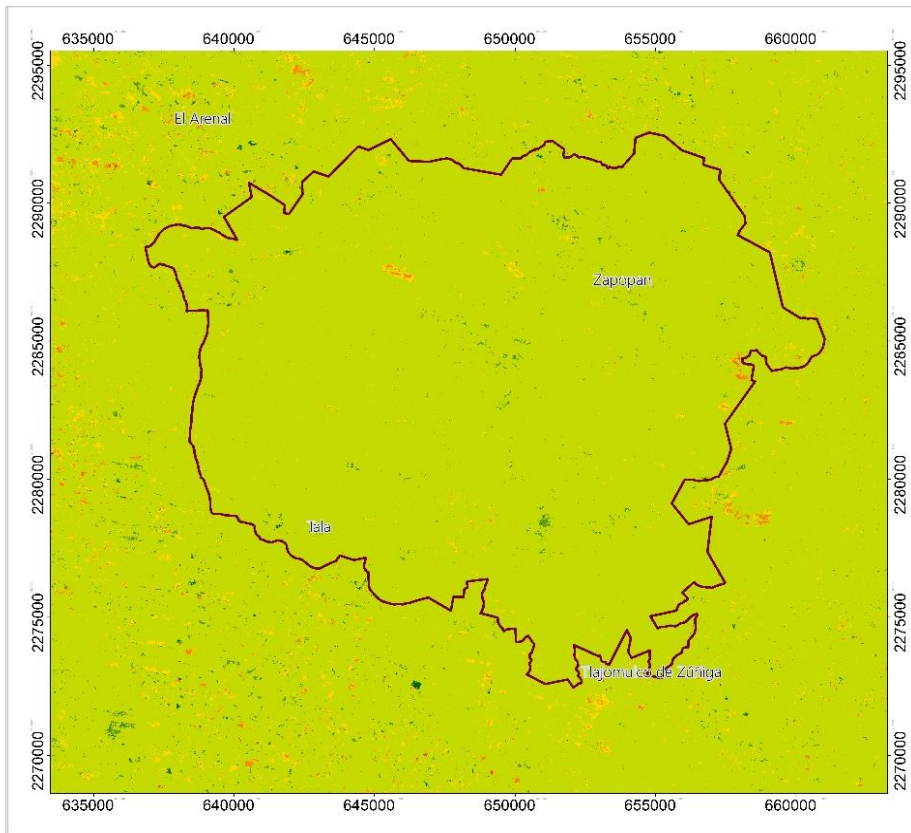


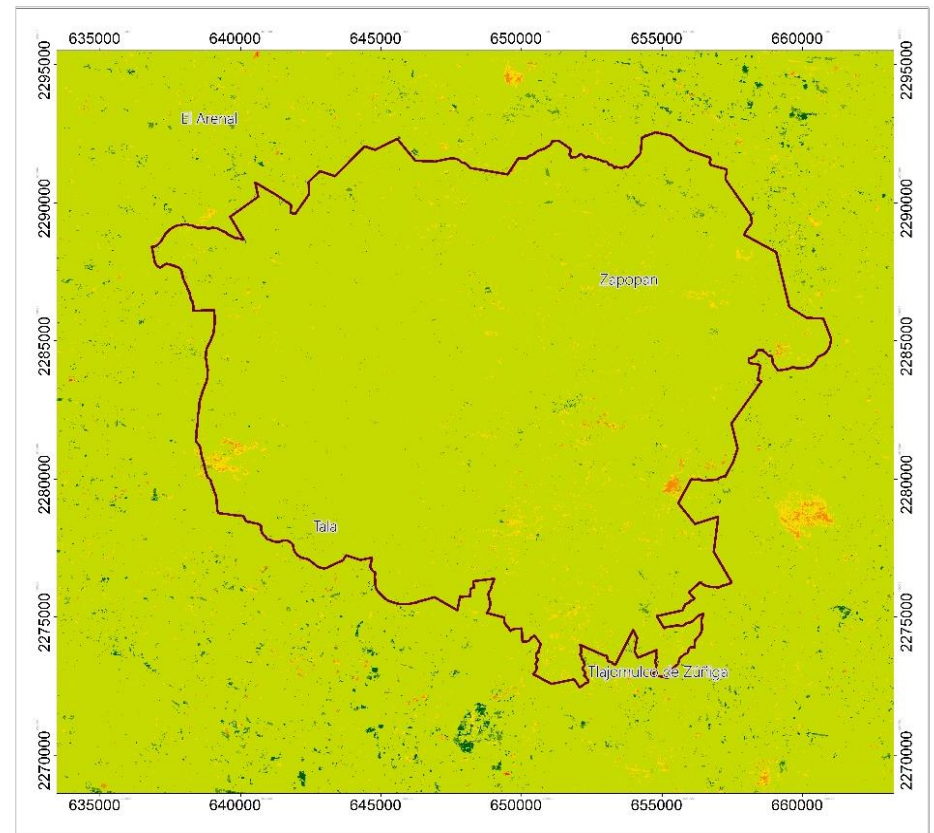
Figura 37. Mapas de proxy-severidad de la quema basados en ΔNBR 2008 y 2009, $h=0.23$

(m) dNBR 2008; (n) dNBR 2009. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(ñ) dNBR - 2010



(o) dNBR - 2011


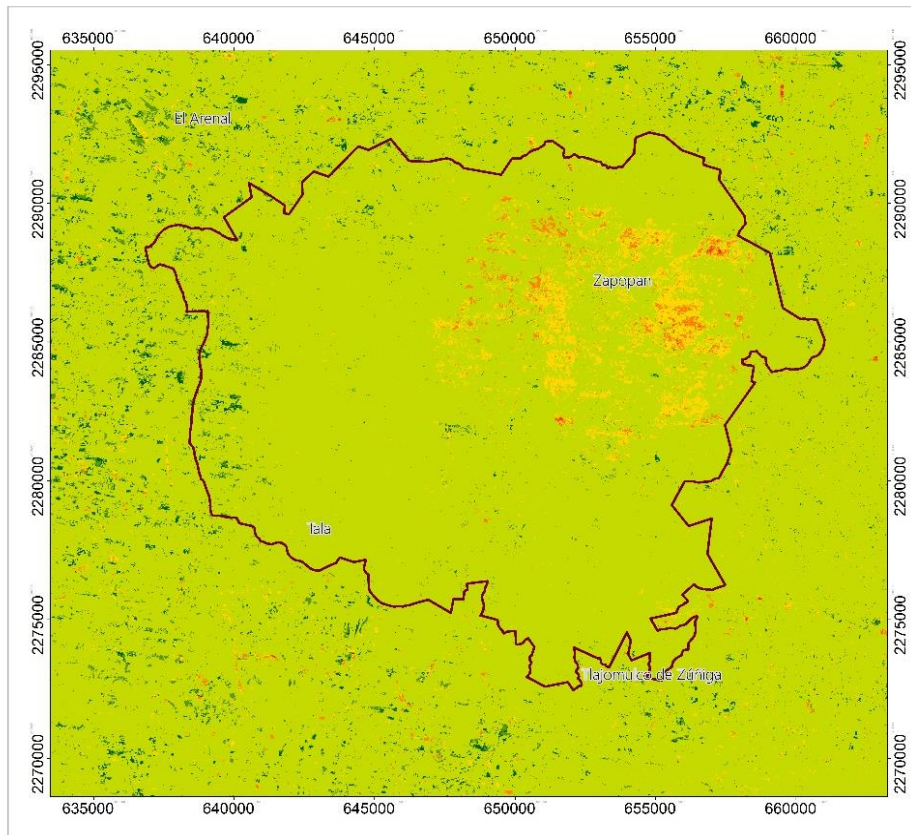


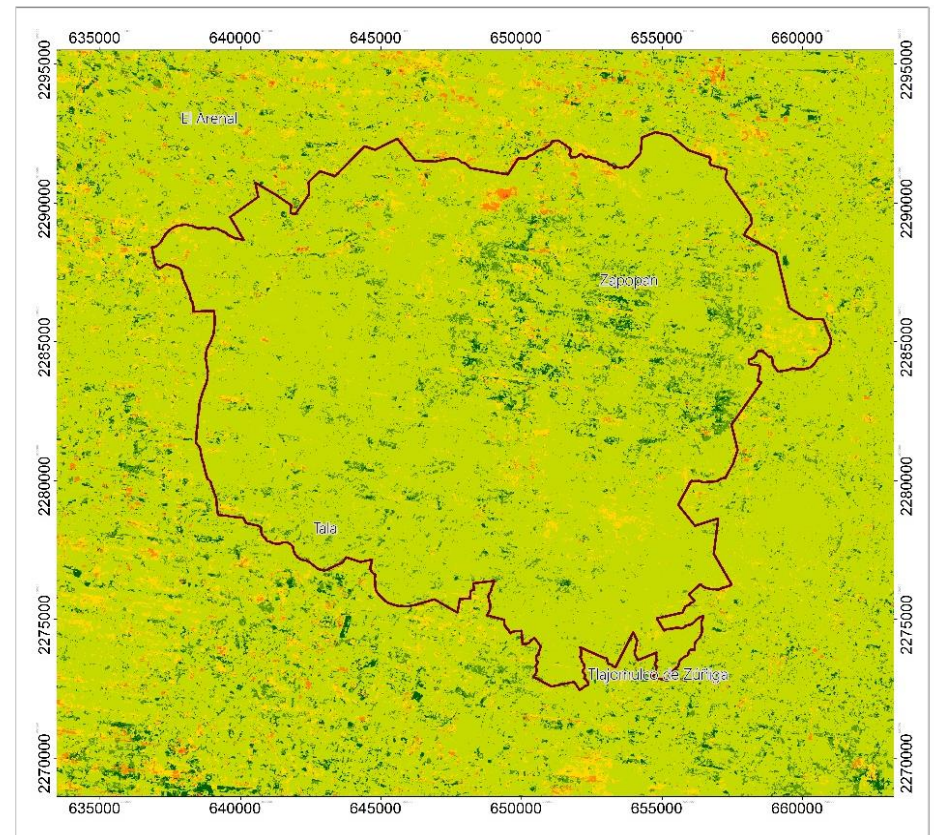
Figura 38. Mapas de proxy-severidad de la quema basados en ΔNBR 2010 y 2011, $h=0.23$

(ñ) dNBR 2010; (o) dNBR 2011. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Proxy-severidad de la quema



(p) dNBR - 2012



(q) dNBR - 2013




Figura 39. Mapas de proxy-severidad de la quema basados en ΔNBR 2012 y 2013, $h=0.23$

(p) dNBR 2012; (q) dNBR 2013. Alto rebrote posterior al fuego: $\Delta NBR < -0.25$; Alto rebrote posterior al fuego: $\Delta NBR [-0.25, -0.1]$; No quemado o No cambio: $\Delta NBR [-0.1, 0.1]$; Severidad baja: $\Delta NBR [0.1, 0.27]$; Severidad media: $\Delta NBR [0.27, 0.66]$; Severidad alta: $\Delta NBR [0.66, 1]$. ELABORACIÓN PROPIA.

Los resultados para los años 2003, 2004, 2015 y 2016 utilizando $h=0.15$ no se presentan al igual que para los años 2003, 2004, 2005, 2014, 2015 y 2016 utilizando $h=0.23$, debido a la manera en que fue diseñado el método y el valor de h utilizado. Estos mapas de proxy-severidad de la quema están basados tanto en el cambio abrupto detectado (como se menciona en el apartado 3.3) en la escala anual, como en los índices de severidad de la quema correspondientes.

Como se puede observar en las figuras anteriores, con el método empleado y utilizando un valor de $h=0.15$ se detectaron áreas quemadas en los años 2005, 2006, 2007, 2008, 2009, 2010, 2011, 2012 y 2013 por otra parte utilizando un valor de $h=0.23$ se detectaron áreas quemadas en los años 2006, 2007, 2008, 2009, 2010, 2011, 2012 y 2013. Sin embargo, esto no quiere decir que en los años restantes no ocurrieron incendios, ya que, en los años 2003, 2004, 2005, 2014, 2015 y 2016 sí se reportaron incendios (Secretaría de Medio Ambiente y Desarrollo Territorial, 2019), pero el método utilizado no fue capaz de detectar áreas quemadas en dichos años, posiblemente por factores relacionados con el rellenado de datos, por la forma en que fue diseñado el método, porque las áreas quemadas hayan sido muy pequeñas o por el tipo y gravedad de estas.

De todos los incendios ocurridos en el APFFLP, los ocurridos en los años 2005 y 2012 fueron los más grandes y devastadores, afectando 8,400 ha y 8,276 ha respectivamente de la superficie total del área de estudio (Del Castillo, 2006; Delgado, 2012).

En el incendio ocurrido en 2005 que se ilustra en la figura 31(a), se observa que el método lo clasificó dentro de un nivel de severidad media en la mayoría del área afectada y en menor medida con un nivel de severidad baja, y alta sólo en algunas áreas muy pequeñas. Si observamos el siguiente año 2006 en la figura 31(b), podemos ver que los niveles de severidad cambiaron, ahora presenta un crecimiento bajo en la vegetación en el área que anteriormente fue quemada. Sin embargo, si observamos el mismo año, pero en la figura 36(k) podemos notar que presenta un alto crecimiento en la vegetación y pequeñas áreas quemadas con niveles de severidad baja-media. Si observamos dos años después de la quema del 2005, es decir, el año 2007 en la figura 32(c), el área afectada en su mayoría está clasificada como no quemado o no cambio y algunas partes (en las que la severidad del incendio fue media-baja) está clasificada

como un alto crecimiento o rebrote de la vegetación posterior al incendio, por otro lado, en la figura 36(l), el área afectada en su mayoría ahora está clasificada como no quemado o no cambio. En 2006 y 2007 el algoritmo utilizado detectó pequeñas áreas quemadas aisladas dentro del APFFLP con un grado de severidad media y baja-media, respectivamente (figuras 31(b), 32(c) y 36(l)).

En el 2008 (tres años después) en la figura 32(d) y 37(m), podemos observar que la mayoría del área afectada por el incendio de 2005, está clasificada como no quemada o no cambio. Sin embargo, para este mismo año, al noreste y sureste del APFFLP un nuevo incendio consumió una parte del área, el cual fue considerado como intencional y a la fecha no se tiene reportada una cifra oficial de la superficie afectada (Huerta e Ibarra, 2014; Velasco, 2010). Se puede notar que presenta un nivel de severidad media en la mayoría del área afectada y una severidad baja y alta sólo en pequeñas áreas.

En el año 2009 (figuras 33(e) y 37(n)) se observa un bajo crecimiento de la vegetación en la parte noreste y en la parte sureste, también hay un bajo crecimiento de la vegetación, pero una pequeña área muestra un nivel de severidad baja en el área afectada en 2008, y en 2010 esta misma área se clasifica como no quemado o no cambio. Para el año 2009, también el algoritmo detectó pequeños incendios distribuidos en varias partes del APFFLP con severidad baja-media.

Para el año 2010 (figuras 33(f) y 38(ñ)), se volvió a presentar otro incendio afectando una superficie pequeña del APFFLP en la parte este, con una severidad baja. Para el 2011 (figura 34(g) y 38(o)), esta misma área presentó un bajo rebrote de la vegetación y no cambio en algunas partes. Así como también pequeñas áreas quemadas dispersas en diferentes partes del APFFLP que, aunque no haya datos de las áreas afectadas, pero sí hay noción de que para este año sí ocurrieron incendios, el método fue capaz de detectar algunas como se muestran en dichas figuras.

Las figuras 34(h) y 39(p)) ilustran el incendio ocurrido el 21 de abril de 2012, en la que podemos observar que presentó una severidad baja-media en la mayoría del área quemada y muy pocas áreas corresponden con una severidad alta. En el siguiente año (2013), podemos observar que en la misma área afectada en 2012 hubo un bajo rebrote posterior al fuego en la mayoría del

área y alto rebrote sólo en algunas partes del área afectada (figuras 35(i) y 39(q)). También se puede ver que en la parte noreste un nuevo incendio afectó al APFFLP presentando una severidad media en la mayor parte del área afectada. Esto ilustra lo descrito anteriormente en las figuras 27, 29 y 30 en la que BFAST detectó un punto de cambio dentro de la serie de tiempo en esos años.

Finalmente, en el 2014 (figura 35(j)), en la misma área afectada en 2013 se observa un bajo y alto crecimiento o rebrote de la vegetación y este año fue en el que la vegetación sufrió menos perturbaciones pues, aunque sí hubo episodios de incendios en diferentes partes del APFFLP estos fueron muy pequeños y dispersos, y sólo afectaron una sexta parte de las hectáreas en el registro de 2013 (El informador, 2016).

El total de hectáreas quemadas por año del 2005-2014 (utilizando $h=0.15$) y 2006-2013 (utilizando $h=0.23$) se muestran en la figura 40. Se observó que este total es aproximado de acuerdo a lo que el algoritmo detectó, los años con más superficie quemada fueron 2005, 2012, seguido 2008 y 2013 utilizando un valor de $h=0.15$, para el valor de $h=0.23$ los años con más superficie quemada fueron 2012, 2013 y 2008. En general con $h=0.15$ el área total quemada es mayor en la mayoría de los años.




Figura 40. Gráfica del total aproximado de hectáreas quemadas detectadas con cada valor de h

Las figuras 41, 42 y 43 ilustran el total aproximado de hectáreas quemadas por nivel de severidad del 2005-2014 para $h=0.15$ y del 2006-2013 para $h=0.23$. Al igual que en la figura

anterior estos totales son aproximados de acuerdo a lo que el algoritmo detectó. Se observa que tanto para $h=0.15$ como para $h=0.23$ la mayoría de las superficies afectadas presentan un nivel de severidad baja y la menor superficie afectada presenta un nivel de severidad alta. Los años con mayor área afectada en los niveles de severidad baja y media fueron 2005 seguido de 2012 y 2008, con nivel de severidad alta fueron 2008, 2012 y 2005. Se puede notar que con $h=0.15$ el área quemada detectada en sus diferentes niveles de severidad es mayor en comparación con $h=0.23$. Sin embargo, con $h=0.23$ solo en el año 2013 el área quemada detectada en los diferentes niveles de severidad fue mayor en comparación con $h=0.15$.




Figura 41. Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad baja




Figura 42. Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad media




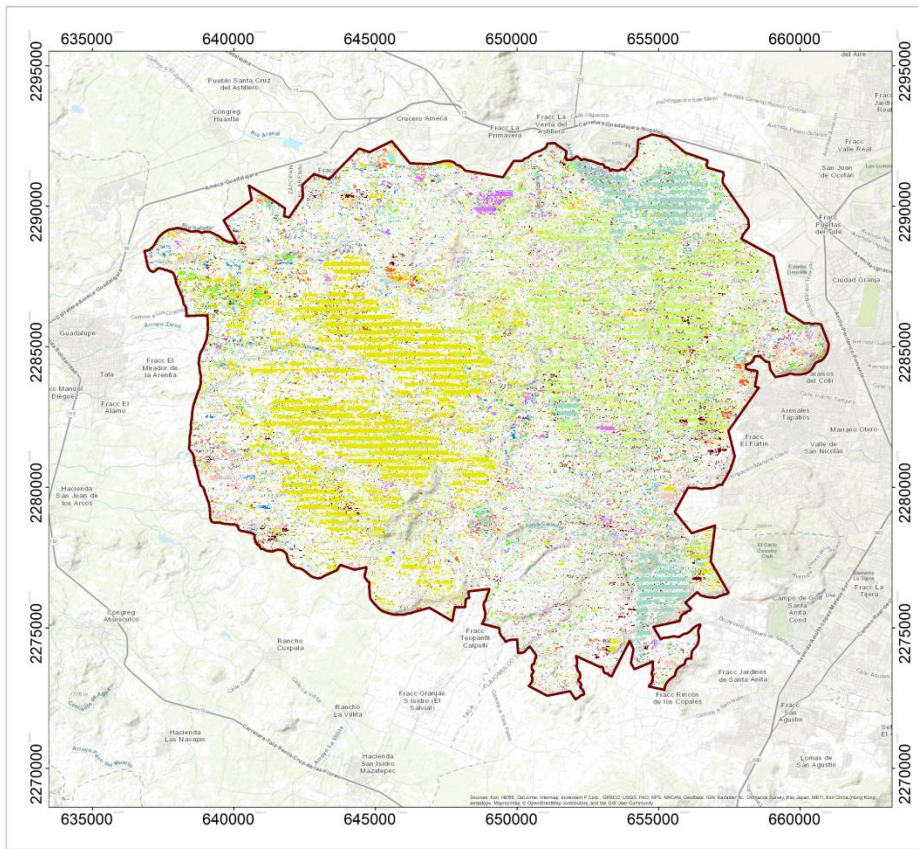
Figura 43. Gráfica del total de hectáreas quemadas aproximadas con un nivel de severidad alta

Por otra parte, en las figuras 44 y 45 se ilustran espacialmente la acumulación de áreas quemadas detectados en el periodo 2003-2016.

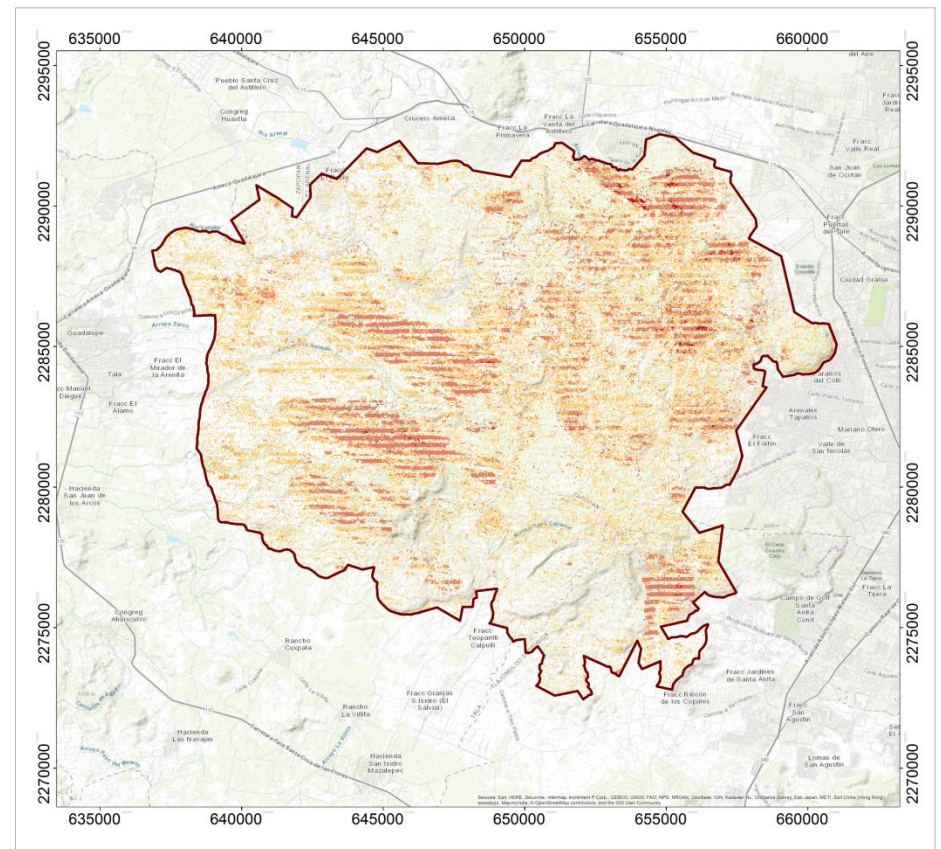
En la figura 44(A) solo se muestran las áreas quemadas del 2005 al 2014 para $h=0.15$ y en la figura 45(A) se muestran las áreas quemadas del 2006 al 2013 para $h=0.23$, ya que, por razones explicadas anteriormente, las áreas quemadas de los años faltantes no se muestran.

En la figura 44(B) se puede notar que la mayoría de las áreas quemadas detectadas tuvieron un nivel de severidad baja-media (11338 hectáreas) y muy pocas áreas con severidad alta (69 hectáreas) en la mayor de los años. En la figura 45(B) podemos ver que la mayoría de las áreas quemadas detectadas tuvieron un nivel de severidad baja (5925 hectáreas) y pocas áreas con severidad media (1422 hectáreas) y alta (51 hectáreas).

Por lo tanto, con un valor de $h=0.15$ las áreas quemadas detectadas de acuerdo a su nivel de severidad también son mayores en comparación con $h=0.23$.



(A) Áreas quemadas detectadas por año



(B) Nivel de severidad de las quemas 2005-2014

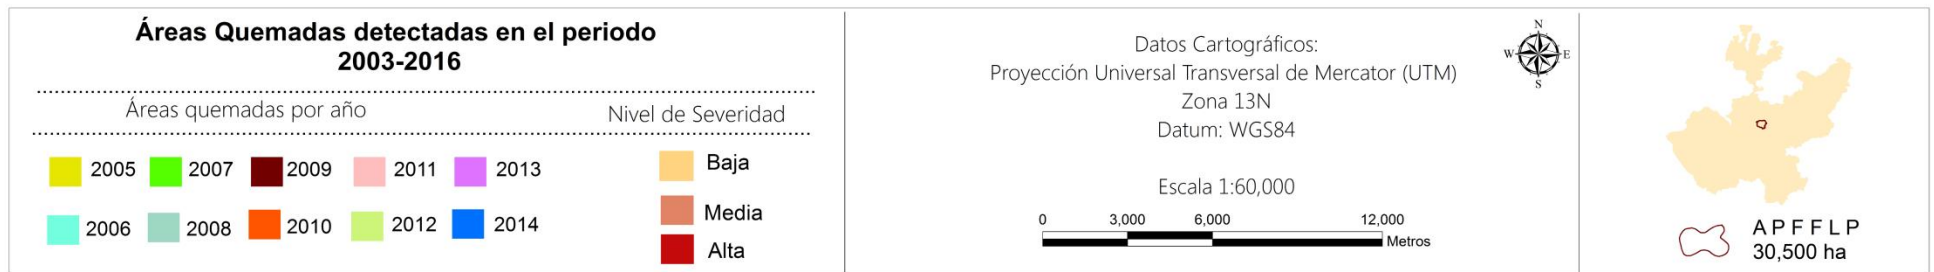
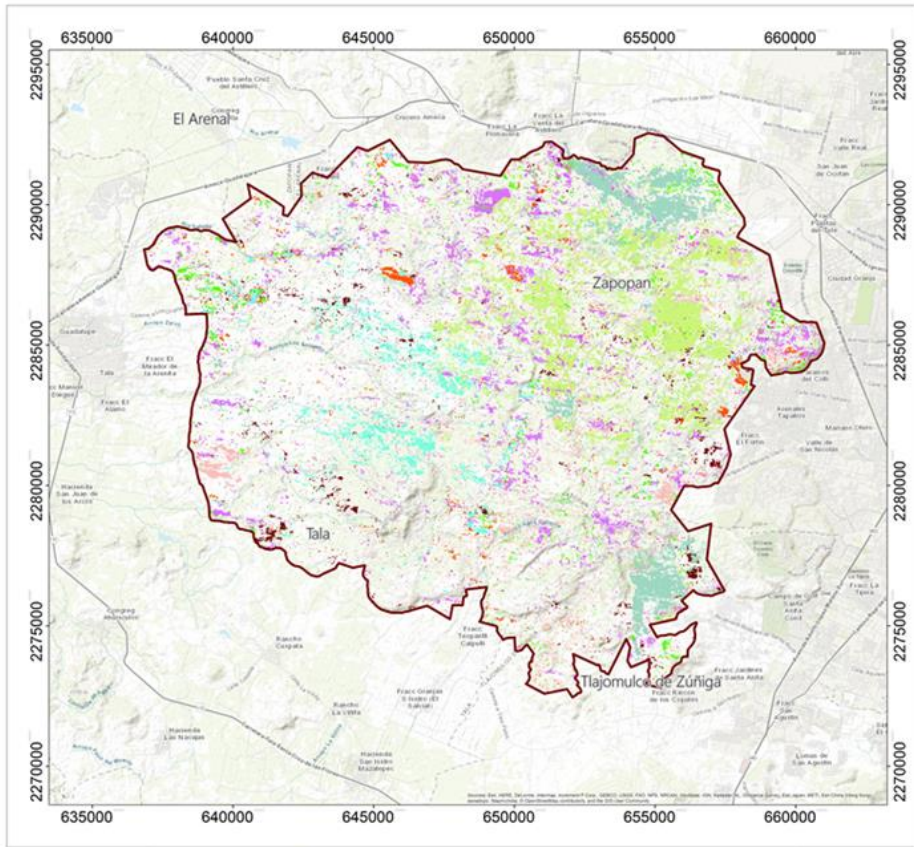
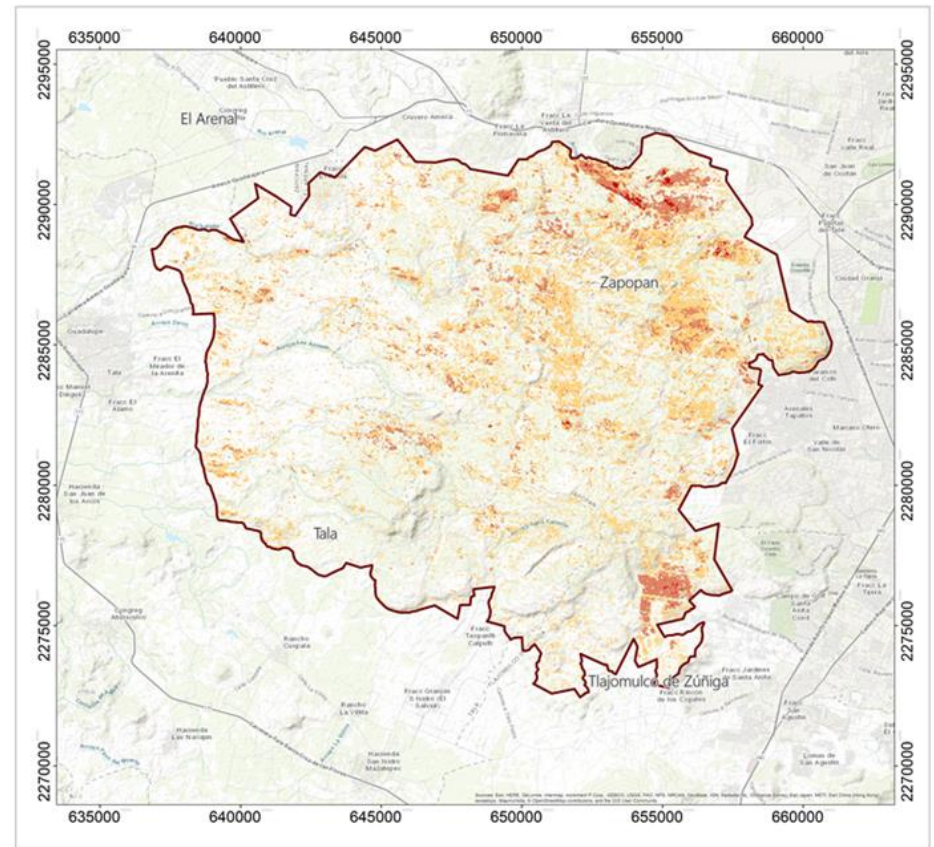


Figura 44. Mapa del total de áreas quemadas detectadas y nivel de severidad de las quemas en el periodo 2003-2016 basados en ΔNBR para el valor de $h=0.15$
 ELABORACIÓN PROPIA.



(A) Áreas quemadas detectadas por año



(B) Nivel de severidad de las quemas 2006-2013



Figura 45. Mapa del total de áreas quemadas detectadas y nivel de severidad de las quemas en el periodo 2003-2016 basados en ΔNBR para el valor de $h=0.23$

ELABORACIÓN PROPIA.

4.6 VALIDACIÓN

4.6.1 Evaluación de la exactitud del área quemada del año 2012

Dada la magnitud del incendio en 2012, diversos esfuerzos fueron coordinados para cuantificar el impacto de tal incendio en esa zona como se menciona en la sección 3.6.1 (figuras 46 y 47). Por ejemplo, la CONABIO realizó un mapa de estimación de área quemada con imágenes RAPIDEYE para este mismo año, el cuál fue elaborado a partir del cálculo del NDVI y NBR, y posteriormente se estableció un umbral para identificar dicho incendio. Por tal motivo, se muestra, a modo de ejemplo, cómo validar el mapa de severidad de incendios obtenido a través de nuestros análisis contra la “verdad”, dada en este caso por un mapa de mayor resolución espacial.

De acuerdo al cálculo realizado con el método 23_A. I (23 escenas antes del incendio), 1_D.I. (1 escena después del incendio) descrito en la sección 3.3 utilizando $h=0.15$ (figura 46), se encontró que el algoritmo en cuanto a la identificación de área quemada obtuvo una exactitud global del 57.14%. Se observa que el mapa final resultante presenta un bandeamiento lo que origina que el área no esté completamente llena dentro del área considerada como quemada de acuerdo con la referencia. Por lo cual la exactitud global del mapa es relativamente baja.

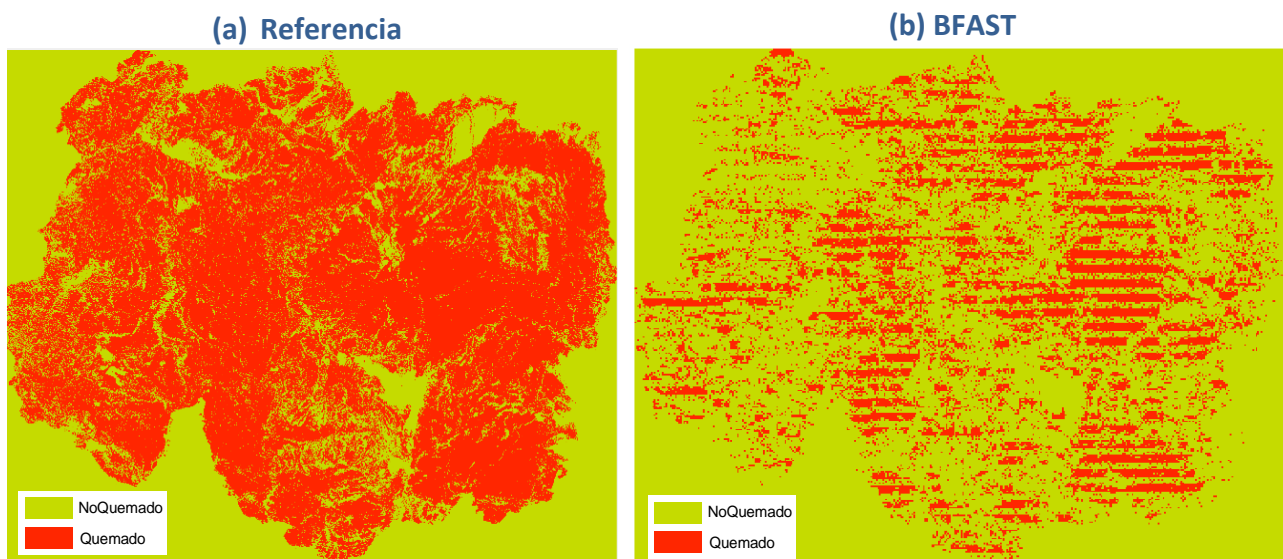


Figura 46. Evaluación de la exactitud del área quemada de 2012, $h=0.15$

(a) Área quemada 2012 delimitada con RAPIDEYE; (b) Área quemada 2012 obtenida con el algoritmo BFAST, con $h=0.15$ (método 23 A. I, 1 D. I).

Por otra parte, aplicando el mismo método 23_A. I, 1_D. I (descrito en el apartado 3.3) pero utilizando un valor de $h=0.23$ (figura 47), se encontró que el algoritmo en cuanto a la identificación de área quemada obtuvo una exactitud global del 55.05%. Este mapa presenta una exactitud global relativamente más baja en comparación con la exactitud anterior, se observa que el área no presenta bandeamiento, sin embargo, se pueden notar áreas de diferentes tamaños dentro del área considerada como quemada y por lo tanto el área no está completamente llena como se muestra en la referencia.

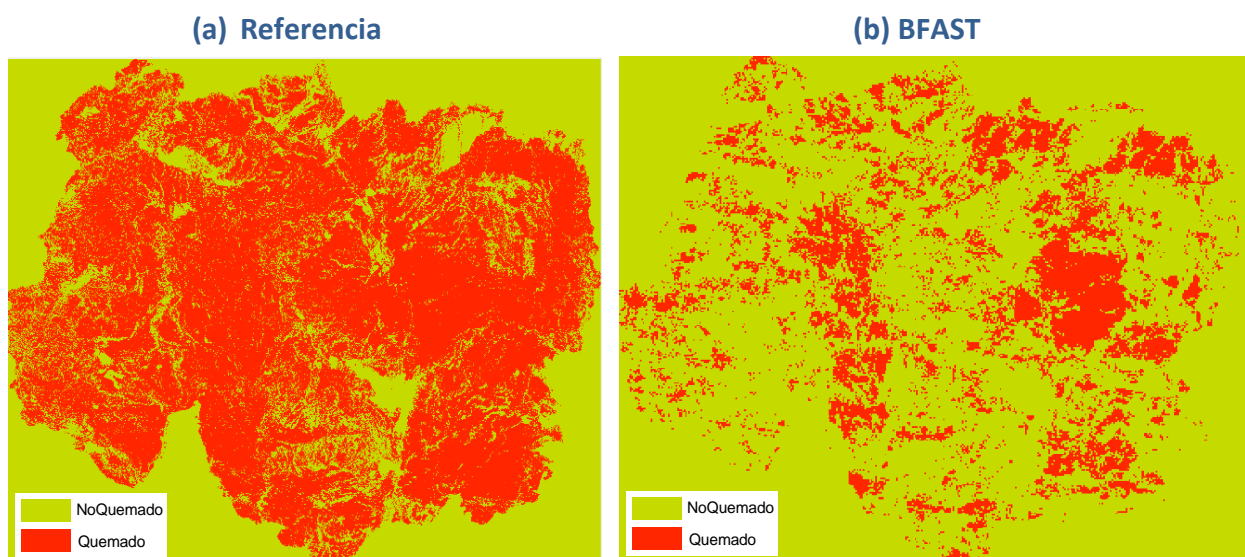


Figura 47. Evaluación de la exactitud del área quemada de 2012, $h=0.23$

(a) Área quemada 2012 delimitada con RAPIDEYE; **(b)** Área quemada 2012 obtenida con el algoritmo BFAST, con $h=0.23$ (23_A. I, 1_D. I).

Los resultados anteriores tanto para $h=0.15$ como $h=0.23$ pueden ser debidos a que el rellenado de datos faltantes haya causado algún impacto en el desempeño de BFAST o en el cálculo de dNBR. Se puede notar que utilizando un valor de $h=0.15$ la exactitud global es 2.09% mayor. Aun así, esta exactitud es relativamente baja, esto puede ser atribuido a que el mapa resultante presenta un bandeamiento (figura 46 (b)), y por lo tanto existe gran cantidad de pixeles clasificados como no quemados, cuando en realidad estos deberían estar clasificados como quemados en el mapa.

4.6.1.1 Alternativas para remover aparente bandeo en el mapa de proxy-severidad del área quemada del año 2012

Con el fin de disminuir el impacto de datos faltantes sobre el desempeño de BFAST o el cálculo de la diferencia del NBR se utilizaron diferentes estrategias y un método de suavizamiento espacial, que ayudarían a mejorar la exactitud del mapa final de área quemada descrito en el punto 4.6.1 para dicho año. Dentro de las estrategias incluidas se encuentra las siguientes:

- A. Se utilizaron dos observaciones de referencia, pero en este caso una observación inmediatamente antes y después, de detectados los puntos de cambio para los dos valores de h ($h=0.15$ y $h=0.23$). Las escenas utilizadas fueron la 214 (corresponde a la escena inmediatamente antes) y 216 (corresponde a la escena inmediatamente después). Los resultados obtenidos a partir de la estrategia descrita anteriormente, se ilustran en la figura 48, se puede observar que a diferencia del método 23_A. I, 1_D. I las áreas consideradas como quemadas (rojo) se presentan como puntos pequeños dispersos sobre todo el límite del área quemada.




Figura 48. Estrategia A para remover aparente bandeo del mapa de proxy-severidad del 2012
(a) Área quemada 2012 obtenida con el algoritmo BFAST, utilizando $h=0.15$; (b) Área quemada 2012 obtenida con el algoritmo BFAST, utilizando $h=0.23$.

- B. Se utilizó el método 23_A. I, 1_D. I y los dos valores de h ($h=0.15$ y $h=0.23$) pero ahora a las escenas se les aplicó un filtro a través del programa ArcMap 10.3.1. Por lo cual, el

cubo de información utilizado contenía 238 escenas al que se le aplicó un suavizamiento espacial a través del filtro, posteriormente se interpoló a través del método lineal para rellenar los NA's por gaps, nubes y temporalmente (escenas que faltan completamente) para completar el cubo, hasta tener las 322 escenas correspondientes. En la figura 49 se muestran los resultados obtenidos para cada valor de h, en las que podemos notar que las zonas quemadas se presentan como áreas y puntos dispersos sobre todo el límite del área considerada como quemada de acuerdo a la referencia utilizada como verdad del terreno.




Figura 49. Estrategia B para remover aparente bandeo del mapa de proxy- severidad del 2012

(a) Área quemada 2012 obtenida con el algoritmo BFAST, utilizando $h=0.15$; (b) Área quemada 2012 obtenida con el algoritmo BFAST, utilizando $h=0.23$.

- C. En esta estrategia se utilizó el método 23_A. I, 1_D. I y el valor de $h=0.15$, pero en este caso a las escenas utilizadas se les aplicó el algoritmo *gdal_fillnodata* para rellenar los datos faltantes debido al bandeo en las imágenes Landsat-7. Este algoritmo interpola valores para todos los píxeles de *nodata* designados (marcados con ceros en la máscara *MaskBand* que viene junto con las escenas Landsat-7). Para cada píxel, se realiza una búsqueda cónica de cuatro direcciones para encontrar los valores para interpolar. Una vez que todos los valores están interpolados, se aplican cero o más iteraciones de suavizado (filtros promedio de 3x3 en píxeles interpolados) para suavizar los artefactos. Este algoritmo es generalmente adecuado para interpolar regiones faltantes de rásteres

que varían bastante continuamente. También es adecuado para rellenar pequeños agujeros y grietas en imágenes con variaciones más irregulares. En general, no es tan bueno para interpolar un ráster a partir de datos de puntos dispersos. En la figura 50 se muestran los resultados de dicha estrategia en la que se puede observar que las áreas quemadas detectadas se presentan como áreas de diferentes tamaños.




Figura 50. Estrategia C para remover aparente bandeo del mapa de proxy-severidad del 2012, utilizando $h=0.15$

4.6.1.2 Comparación de las exactitudes de los diferentes métodos usados para remover aparente bandeo en el mapa de proxy-severidad del año 2012

En términos generales, las exactitudes globales de la detección de áreas quemadas del año 2012 para cada una de las estrategias y el método 23_A. I, 1_D. I con $h=0.15$ y $h=0.23$ se muestran en la figura 51.

Se observa que la estrategia A con $h=0.15$ y $h=0.23$ presenta exactitudes globales de 56.01% y 56.89% respectivamente. En la estrategia B para $h=0.15$ y $h=0.23$ las exactitudes globales son de 57.40% y 58.84% respectivamente y la estrategia C presenta una exactitud global del 53.29%. Visualmente y cuantitativamente notamos que utilizando $h=0.23$ en las dos estrategias A y B, la exactitud del área quemada es más alta.

El método 23_A. I, 1_D. I con $h=0.15$ presenta exactitudes globales ligeramente más altas con respecto a la estrategia A de 1.13% para $h=0.15$ y de 0.25% para $h=0.23$, y con respecto a la estrategia B presenta exactitudes globales más bajas para los dos valores de h de dicha estrategia. Las estrategias A y B presentan exactitudes más altas con respecto al método 23_A. I, 1_D. I con $h=0.23$.

La estrategia que posiblemente mejora un poco la exactitud global de la detección de área quemada es la estrategia B tanto para $h=0.15$ como para $h=0.23$ ya que mejoran la exactitud 0.26% y 1.7% respectivamente, del método 23_A. I, 1_D. I con $h=0.15$. Y si comparamos esta estrategia con el método 23_A. I, 1_D. I con $h=0.23$ mejora 2.35% para $h=0.15$ y 3.79% para $h=0.23$. La estrategia C es la que presentó la exactitud más baja de todas las estrategias, sin embargo, visualmente es la que mejor representa el fenómeno.

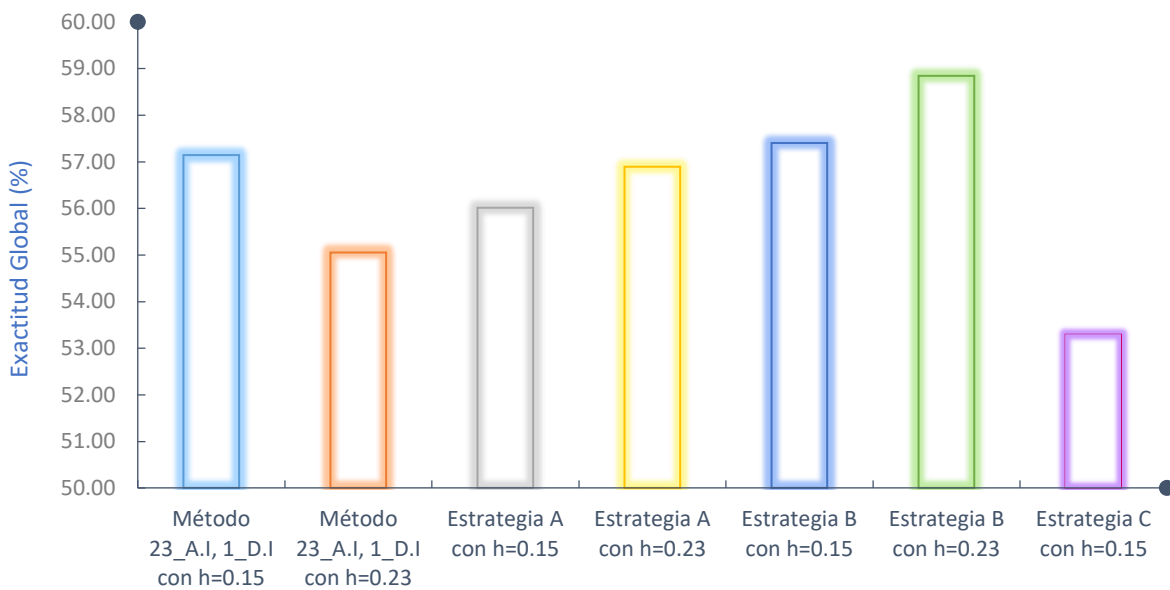


Figura 51. Gráfica comparativa de la exactitud global de las diferentes estrategias utilizadas vs el método 23_A. I, 1_D. I para la quema del 2012

Las matrices de error o confusión de los cálculos de la exactitud global, las exactitudes del usuario/productor para cada clase quemado/no quemado y por estrategia para el año 2012 se muestra en las tablas 8 a la 14.

Tabla 8. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (método 23_A. I, 1_D. I, $h=0.15$)

Mapa resultante de BFAST						
Referencia		1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q		4651	3571	8222	56.57
2. NQ		526	812	1338	60.69	39.31
Total		5177	4383	9560		
	Exactitud Usuario (%)	89.84	18.53			
	Error Comisión (%)	10.16	81.47			
Exactitud Global (%) 57.14						

Q= Clase Quemada; NQ = Clase No Quemada

Al analizar la tabla 8, la clase quemada (Q), tiene una baja exactitud del productor (56.57%), esto quiere decir que el 56.57% de la verdad del terreno (referencia) fue clasificado correctamente, contra una exactitud de usuario aceptable del 89.84%. En cuanto al error de omisión para la misma clase Q fue del 43.43%, es decir, que el 43.43% de los pixeles que tenían que haber sido clasificados como quemados no fueron asignados en el mapa en la clase Q. Por otra parte, el 10.16% de pixeles etiquetados como Q en el mapa no lo estaban, es decir, pertenecían a la clase No Quemado (NQ) este porcentaje representan el error de comisión.

Para la clase NQ se observa que a diferencia de la clase Q la exactitud de productor es más alta (60.69%) y la exactitud de usuario más baja (18.53%), esto quiere decir que, el 18.53% de la clase clasificada como NQ en el mapa verdaderamente representa a esa categoría en el terreno, con errores de comisión y omisión del 81.47% y 39.31% respectivamente, es decir se omitieron el 39.31% de los pixeles NQ y se cometió el error de etiquetar el 81.47% de la clase NQ cuando en realidad estaban quemados. Estos errores o confusión entre las clases producido de forma aleatoria pueden ser debidos a varios factores; uno al bandeamiento que presenta el mapa resultante posiblemente debido al relleno de huecos en las imágenes originales; o a las pequeñas islas de vegetación no quemadas dentro del incendio; o a las diferencias temporales de las imágenes utilizadas para realizar la dNBR. En resumen, se puede observar que la clase NQ presenta una exactitud más alta, omisión baja y comisión alta, en comparación con la clase Q que tuvo una exactitud más baja, omisión alta y comisión baja.

Por otra parte, la tabla 9 muestra la matriz de confusión del mapa con un valor de $h=0.23$ en la que podemos observar que a diferencia de la tabla 8, la clase Q tiene una exactitud de productor más alta del 57.03% y por lo tanto un error de omisión bajo del 42.97%. Para la clase NQ la exactitud del productor es más baja (48.09%) y por lo tanto un error de omisión más alto (51.91%), esto quiere decir que para la clase NQ se omitieron el 51.91% de los pixeles que deberían ser NQ y solo el 48.09% fueron clasificados correctamente, para la clase Q solo el 42.97% de los pixeles quemados fueron omitidos y el 57.03% fueron clasificados correctamente. En cuanto a la exactitud de usuario para la clase Q y NQ fueron del 79.38% y 24.21% respectivamente, se cometió el error de etiquetar el 20.62% de la clase Q cuando en realidad no lo estaban y para la clase NQ se cometió el error de etiquetar el 75.79% de los pixeles en esta clase cuando en realidad estaban quemados.

Tabla 9. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (método 23_A. I, 1_D.I, $h=0.23$)

Mapa resultante de BFAST						
		1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
Referencia	1. Q	2352	1772	4124	57.03	42.97
	2. NQ	611	566	1177	48.09	51.91
	Total	2963	2338	5301		
Exactitud Usuario (%)		79.38	24.21			
Error Comisión (%)		20.62	75.79			
					Exactitud Global (%)	55.05

Q= Clase Quemada; NQ = Clase No Quemada

Los resultados de las matrices de confusión correspondientes a la estrategia A por cada valor de h (Tabla 10 y 11) indican que sólo un 43.23% y 42.72% de los pixeles de la clase Q fueron omitidos, pero para la clase NQ el porcentaje de pixeles omitidos fue de 59.93% y 58.82% respectivamente. La exactitud del productor en ambas tablas es baja con un 56.77% y 57.28% para la clase Q, así como para la clase NQ que es todavía más baja con un 40.07% y 41.18%. Sin embargo, en ambas matrices la clase Q tiene una exactitud de usuario elevada, con el 95.23% y el 97.51% de áreas mapeadas correctamente, y la clase NQ presenta exactitudes muy bajas del

4.21% y 2.34%. Por otro lado, los errores de comisión para la clase Q son muy bajos con 4.77% y 2.49%, pero para la clase NQ ascienden a más del 95%, ya que se etiquetaron pixeles como NQ cuando tendrían que estar dentro de la clase Q.

Tabla 10. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia A, $h=0.15$)

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	10251	7807	18058	56.77
2. NQ	513	343	856	40.07	59.93
Total	10764	8150	18914		
Exactitud Usuario (%)	95.23	4.21			
Error Comisión (%)	4.77	95.79			
Exactitud Global (%)					56.01

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 11. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia A, $h=0.23$)

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	9806	7312	17118	57.28
2. NQ	250	175	425	41.18	58.82
Total	10056	7487	17543		
Exactitud Usuario (%)	97.51	2.34			
Error Comisión (%)	2.49	97.66			
Exactitud Global (%)					56.89

Q= Clase Quemada; NQ = Clase No Quemada

Las tablas 12 y 13 ilustran las matrices de confusión de la estrategia B para cada valor de h y muestran que el 40.21% y 38.17% de los pixeles de la clase Q fueron omitidos y para la clase NQ el porcentaje de pixeles omitidos fueron menores del 28.55% y 15.40%, respectivamente. La exactitud de productor y usuario para la clase NQ en ambas tablas es un poco alta en comparación con la clase Q. Los errores de comisión para la clase Q en ambas tablas son bajos

de 2.55% y 1.43%, sin embargo, para la clase NQ estos errores son muy altos de 91.13% y 88.54%, esos porcentajes altos son debidos a que hay gran cantidad de pixeles clasificados como NQ cuando en realidad tendrían que estar clasificados como Q.

Tabla 12. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia B, $h=0.15$)

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	8139	5473	13612	59.79
2. NQ	213	533	746	71.45	28.55
Total	8352	6006	14358		
Exactitud Usuario (%)	97.45	8.87			
Error Comisión (%)	2.55	91.13			
Exactitud Global (%)					60.40

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 13. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia B, $h=0.23$)

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	6670	4117	10787	61.83
2. NQ	97	533	630	84.60	15.40
Total	6767	4650	11417		
Exactitud Usuario (%)	98.57	11.46			
Error Comisión (%)	1.43	88.54			
Exactitud Global (%)					63.09

Q= Clase Quemada; NQ = Clase No Quemada

La tabla 14 ilustra la matriz de confusión de la estrategia C y muestra que el 42.70% de los pixeles de la clase Q fueron omitidos y para la clase NQ el porcentaje de pixeles omitidos fue mayor del 53.02%. Por otra parte, se cometió más error al clasificar a la clase NQ que a la clase Q, por lo que hay gran cantidad de pixeles clasificados como NQ cuándo deberían estar clasificados como Q. La exactitud de productor y usuario para la clase Q es un poco alta en comparación con la clase NQ que fueron más bajas.

Si comparamos la estrategia C con el método inicial propuesto, presenta una exactitud global más baja y la clase NQ tiene un error de comisión más bajo pero un error omisión un poco más alto, cuando con la clase Q sucede lo contrario.

Tabla 14. Matriz de confusión del mapa resultante de BFAST del área quemada del 2012 (estrategia C, $h=0.15$)

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	1641	1223	2864	57.30
2. NQ	966	856	1822	46.98	53.02
Total	2607	2079	4686		
Exactitud Usuario (%)	62.95	41.17			
Error Comisión (%)	37.05	58.83			
				Exactitud Global (%)	53.29

Q= Clase Quemada; NQ = Clase No Quemada

4.6.2 Evaluación de la exactitud del área quemada para el año 2012 utilizando grupos de pixeles con diferente calidad

A través de los estudios de simulación se identificó que BFAST tiene un correcto desempeño cuando el porcentaje de datos faltantes en un pixel es menor al 40%. Esto generó el planteamiento de otra hipótesis: la exactitud de los mapas de área quemada aumentará si la calidad de los pixeles bajo consideración mejora (es decir, los pixeles tienen menos del 40% de datos faltantes). En esta subsección presentamos evidencia empírica para probar esta hipótesis.

Por lo cual se optó por evaluar la exactitud de los mapas a través de pixeles que contenían diferente calidad (cierto porcentaje de datos faltantes). Para esto fue necesario crear una máscara del porcentaje de datos faltantes (NA's) por pixel del área de estudio como se ilustra en la figura 52, en la que podemos observar que la calidad de los pixeles del cubo de datos usado es mala (alto porcentaje de datos faltantes), la mayoría de los pixeles están concentrados entre el 50% hasta el 70% con datos faltantes.

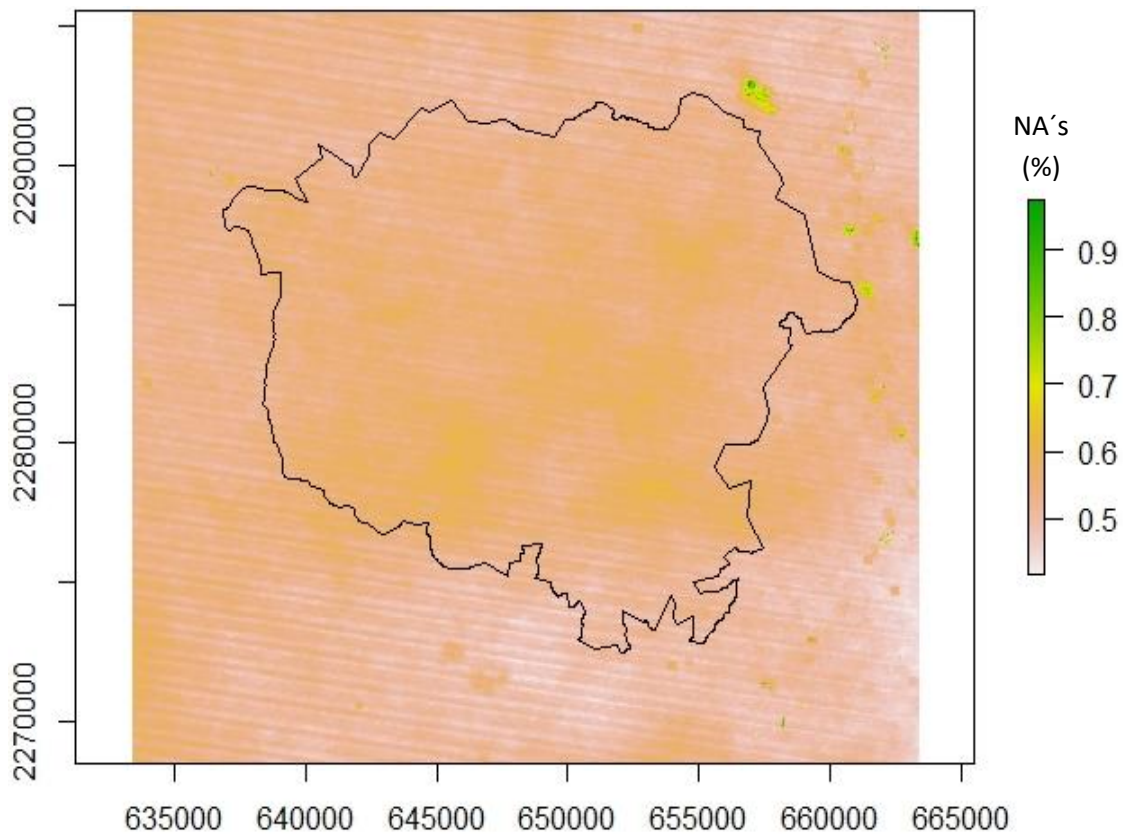


Figura 52. Mapa del porcentaje de datos faltantes (NA's) por pixel del área de estudio

Para evaluar solo el área quemada del 2012 se buscó un rango de valores en los que estuvieran pixeles de mejor y peor calidad para crear una nueva máscara que solo esté dentro de dicho rango de valores. La nueva máscara creada comprende valores entre 41% a 54% de datos faltantes como se ilustra en la figura 53 (a), los cuales se dividieron en dos grupos de pixeles con diferentes porcentajes de datos faltantes (grupo 1: 5, 6 y 7, y grupo 2: 7, 8 y 9). En la figura 53 (a) podemos notar que la mayoría de los pixeles tienen una calidad mala, con un porcentaje de datos faltantes por arriba del 40% representados con colores verde y azul claro, las zonas blancas representan a los pixeles que contienen un porcentaje de datos faltantes mayor al 54%, mientras que la menor cantidad de pixeles representados en color azul fuerte son los que contienen menos del 40% de datos faltantes.

Es evidente que la mayor parte del cubo de información contenía pixeles de baja calidad lo cual se reflejaría en la exactitud de los mapas de severidad mostrada en la sección 4.6.1.2. Sin embargo, cuando nos enfocamos solo en dónde la calidad de los datos no es tan mala (zonas

azules claras grupo 1: 5, 6, y 7, figura 53 (b)) la metodología propuesta funciona aceptablemente bien.

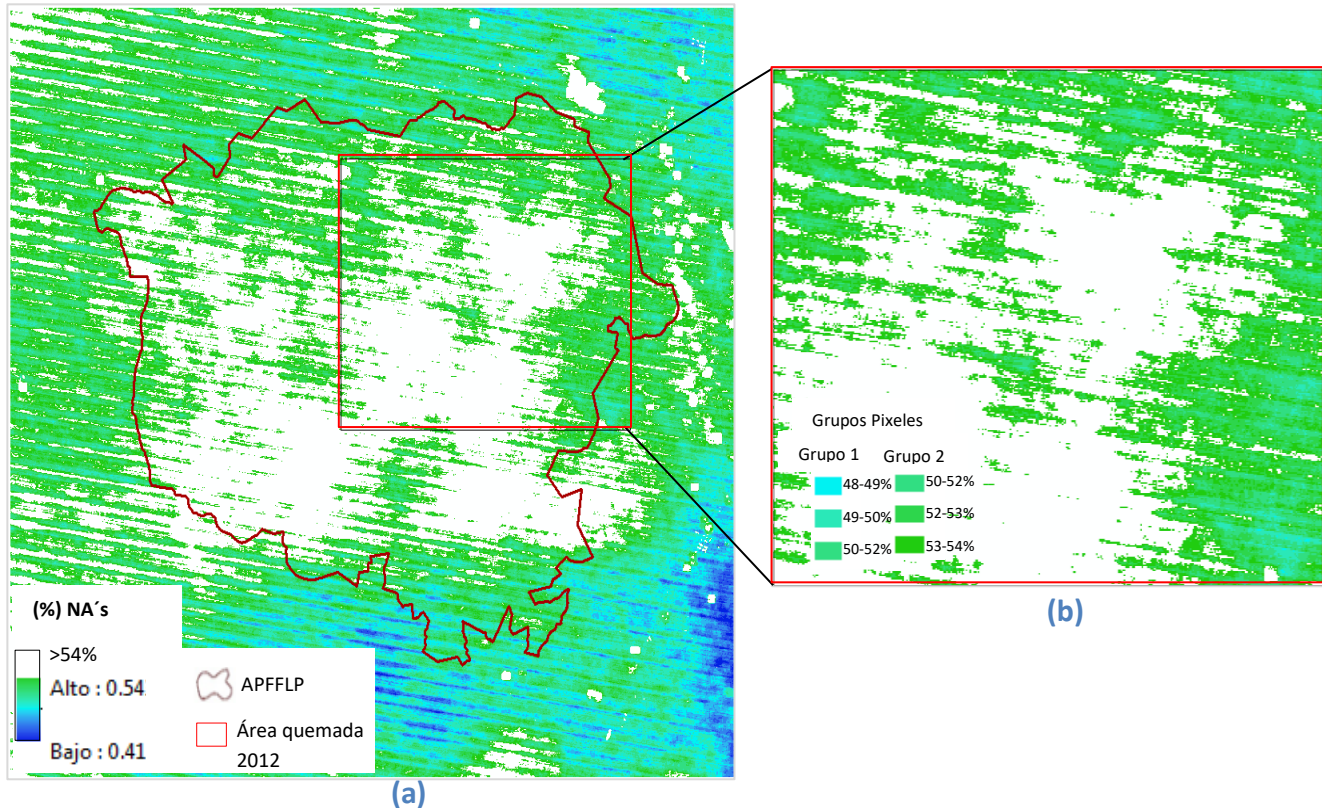


Figura 53. Máscara utilizada para la evaluación de exactitud del área quemada de 2012

(a) Representación del porcentaje de datos faltantes para el área de estudio (APFFLP), el contorno rojo representa el área quemada del 2012; (b) Representación de los dos grupos de datos obtenidos de la máscara para el área quemada de 2012 de acuerdo a la tabla 15.

En la tabla 15 se muestran los porcentajes de datos faltantes por pixel obtenidos de la máscara, que fueron utilizados para realizar la evaluación de exactitud del mapa resultante de área quemada del 2012.

El primer grupo de pixeles utilizado (Grupo 1: 5, 6, y 7) está dentro de un rango de valores de 48% a 52% de datos faltantes, mientras que el segundo grupo de pixeles utilizado (Grupo2: 7, 8 y 9) comprende un rango de valores de 50% a 54% de datos faltantes. El grupo de pixeles 1, 2, 3 y 4 se descartan para este análisis debido a que los pixeles en la zona quemada contienen al menos 48% de datos faltantes (figura 53 (b)).

Tabla 15. Porcentaje de datos faltantes por pixel de la máscara utilizada para la evaluación de exactitud del área quemada de 2012

Calidad de los datos (% NA's)	Grupos de Píxeles
0.41 - 0.44	1
0.44 - 0.45	2
0.45 - 0.46	3
0.46 - 0.48	4
0.48 - 0.49	5
0.49 - 0.50	6
0.50 - 0.52	7
0.52 - 0.53	8
0.53 - 0.54	9
> 0.54	10

Grupo 1: 5, 6 y 7 (línea punteada naranja);

Grupo 2: 7, 8 y 9 (línea punteada azul)

La evaluación de exactitud del área quemada y no quemada se hizo sobre los dos grupos de píxeles con sus respectivos porcentajes de datos faltantes, es decir, la evaluación de exactitud solamente se hizo sobre los píxeles resultantes al aplicar la máscara, para el método inicial propuesto (23_A. I, 1_D. I) y para cada una de las estrategias mencionadas en la sección 4.6.1.1. Las figuras 55 a la 60 ilustran los píxeles resultantes al aplicar la máscara tanto para los datos de referencia como los obtenidos con el algoritmo mostradas en los anexos.

Las matrices de error o confusión del método 23_A. I, 1_D. I y cada una de las estrategias usadas para cada clase quemado/no quemado, de los dos grupos píxeles resultantes al aplicar la máscara del área quemada del 2012, se muestra en las tablas 16 a la 21.

Tabla 16. Matriz de confusión basada en la figura 55 (método 23_A. I, 1_D. I, h=0.15) usando la máscara del grupo 2

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	2341	1621	3962	59.09
2. NQ	276	451	727	62.04	37.96
Total	2617	2072	4689		
Exactitud Usuario (%)	89.45	21.77			
Error Comisión (%)	10.55	78.23			
				Exactitud Global (%)	59.54

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 17. Matriz de confusión basada en la figura 56 (método 23_A. I, 1_D. I, $h=0.15$) usando la máscara del grupo 1

Mapa resultante de BFAST						
Referencia		1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q		364	222	586	62.12
2. NQ		28	144	172	83.72	16.28
Total		392	366	758		
Exactitud Usuario (%)		92.86	39.34			
Error Comisión (%)		7.14	60.66			
Exactitud Global (%) 67.02						

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 18. Matriz de confusión basada en la figura 57 (Estrategia B, $h=0.23$) usando la máscara del grupo 2

Mapa resultante de BFAST						
Referencia		1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q		2621	1574	4195	62.48
2. NQ		36	279	315	88.57	11.43
Total		2657	1853	4510		
Exactitud Usuario (%)		98.65	15.06			
Error Comisión (%)		1.35	84.94			
Exactitud Global (%) 64.30						

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 19. Matriz de confusión basada en la figura 58 (Estrategia B, $h=0.23$) usando la máscara del grupo 1

Mapa resultante de BFAST						
Referencia		1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q		255	141	396	64.39
2. NQ		3	104	107	97.20	2.80
Total		258	245	503		
Exactitud Usuario (%)		98.84	42.45			
Error Comisión (%)		1.16	57.55			
Exactitud Global (%) 71.37						

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 20. Matriz de confusión basada en la figura 59 (Estrategia C, $h=0.15$) usando la máscara del grupo 2

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	667	479	1146	58.20
2. NQ	375	360	735	48.98	51.02
Total	1042	839	1881		
Exactitud Usuario (%)	64.01	42.91			
Error Comisión (%)	35.99	57.09			
Exactitud Global (%)					54.60

Q= Clase Quemada; NQ = Clase No Quemada

Tabla 21. Matriz de confusión basada en la figura 60 (Estrategia C, $h=0.15$) usando la máscara del grupo 1

Mapa resultante de BFAST					
Referencia	1. Q	2. NQ	Total	Exactitud Productor (%)	Error Omisión (%)
	1. Q	94	65	159	59.12
2. NQ	38	76	114	66.67	33.33
Total	132	141	273		
Exactitud Usuario (%)	71.21	53.90			
Error Comisión (%)	28.79	46.10			
Exactitud Global (%)					62.27

Q= Clase Quemada; NQ = Clase No Quemada

Al analizar las tablas anteriores podemos deducir que mientras la calidad de los datos sea buena, es decir, el porcentaje de datos faltantes no sea tan elevado (menor al 40%), la exactitud global en la identificación del área quemada aumentará significativamente al igual que las exactitudes de usuario y productor para cada una de las clases, y por lo tanto los errores de comisión y omisión disminuirán. Estas tablas proveen la evidencia empírica mencionada anteriormente para demostrar la hipótesis planteada.

Si comparamos los resultados de las matrices de error que se muestran en la sección 4.6.1.2 contra el resultado obtenido usando los grupos de píxeles específicos, la exactitud global de identificación del área quemada aumenta (figura 60). Esto está en correspondencia directa con los resultados de las simulaciones realizadas, si tuviéramos un cubo de datos o serie de tiempo

de mejor calidad la exactitud de identificación de área quemada sería más elevada, ya que mientras la calidad de los datos aumenta, la exactitud de identificación de área quemada también aumenta.




Figura 54. Aumento de la exactitud global del área quemada de 2012 utilizando la máscara con los dos grupos de píxeles

V. DISCUSIÓN

Las principales limitantes que surgieron de este estudio fueron la falta de datos generado por el ruido inherente debido a nubes, sombras de nubes y gaps. Por lo cual fue necesario realizar simulaciones que ayudaran a evaluar la robustez del algoritmo BFAST en un ambiente controlado y de esta manera saber qué tanto afectan las limitantes de los datos Landsat-7 sobre la detección de los cambios abruptos.

BFAST trata el ruido en series de tiempo de dos maneras. Primero, se implementa una regresión lineal robusta para reducir la influencia de los valores atípicos (por ejemplo, las nubes) (Venables y Ripley, 2002) al estimar de manera iterativa el modelo estacional y de tendencia. En segundo lugar, se usan tres términos armónicos para estimar el componente estacional de una serie de tiempo y eliminar las variaciones de frecuencia más altas, como el ruido y la dispersión atmosférica (Geerken, 2009).

Aunque BFAST trata el ruido inherente en las series de tiempo, sigue siendo importante la aplicación de otras técnicas disponibles que mejoran la calidad de los datos antes de aplicar el algoritmo, de esta manera tener una mejor detección de los cambios abruptos y por ende una mejor identificación de áreas quemadas. Aquí se estudió la eficiencia del algoritmo (BFAST) en función de esta calidad de datos (medida como porcentaje de datos faltantes).

En la aplicación de BFAST para la detección de los cambios abruptos en las series de tiempo NDVI, el algoritmo sí fue capaz de determinar las áreas quemadas en La Primavera, Jalisco., a pesar de las limitantes presentes en la serie de tiempo Landsat-7. No obstante, al igual que en otro trabajo (Cocke *et al.*, 2005) se observan inexactitudes entre zonas no quemadas y zonas de baja severidad. Se observa que la densidad de arbolado (quemado y no quemado) y los daños causados en el ecosistema están relacionados con los niveles de severidad, por lo que se considera que el índice dNBR es muy útil para examinar los efectos del fuego (corto y largo plazo), en zonas muy afectadas (severidad media y /o alta). De acuerdo a los resultados obtenidos de la validación con respecto del área quemada detectada en 2012 con el método propuesto (método 23_A. I, 1_D. I con $h=0.15$) podemos decir lo siguiente:

- La exactitud global del método 23_A. I, 1_D. I, pero usando $h=0.23$ fue 2.09% más baja. Las exactitudes del productor y usuario para la clase Q fue ligeramente más alta y baja (0.46% más alta y 10.46% más baja) respectivamente y para la clase NQ fue 20.6% más baja y 5.68% más alta respectivamente. En cuanto al error de omisión para la clase Q y NQ fue 0.56% más bajo y 12.6% más alto respectivamente, y se cometió 10.46% más error en la clase Q, en la clase NQ se cometió 5.68% menos error.
- La exactitud global de la estrategia A con $h=0.15$ no mejoró al contrario la exactitud fue más baja (1.13%), en la exactitud del productor también fue baja en la clase NQ y en la clase Q ligeramente más alta (0.2%). El error de omisión en la clase NQ fue 20.62% más alto y en la clase Q se omitió el mismo porcentaje. En cuanto a la exactitud del usuario para la clase Q fue 5.39% más alta y para la clase NQ fue 14.32% más baja. El error de comisión para la clase Q y NQ fue más bajo (7.67%) y más alto (16.19%) respectivamente.
- La exactitud global de la estrategia A con $h=0.23$ cuantitativamente tampoco mejoró siendo 0.25% más baja. En cuanto a la exactitud de productor para las clases Q y NQ fueron 0.71% más alta y 19.51% más baja, por lo tanto, el error de omisión para la clase Q fue más bajo y para la clase NQ fue más alto. Por otra parte, la exactitud de usuario para la clase Q fue también más alta (7.67%) y para la clase NQ más baja. El error de comisión para la clase Q más bajo y para la clase NQ más alto. Por lo anterior podemos decir que con la estrategia A utilizando $h=0.23$ la clase Q es la mejor clasificada, las exactitudes de productor y usuario mejoraron ligeramente y los errores de omisión y comisión bajaron ligeramente. Pero para la clase NQ el error de omisión y comisión, bajó y aumentó respectivamente, por lo tanto, la exactitud de productor y usuario, aumentó y bajó respectivamente.
- La exactitud global de la estrategia B con $h=0.15$ cuantitativamente mejoró, siendo un 3.26% más alta. Las exactitudes de productor y usuario también mejoraron aumentando un 3.22% y 7.61% respectivamente para la clase Q, pero para la clase NQ la exactitud de productor aumento y la exactitud de usuario disminuyó. En cuanto a los errores de

omisión y comisión para la clase Q bajaron respectivamente y para la clase NQ el error de comisión aumento y el error de omisión disminuyó.

- La exactitud global de la estrategia B con $h=0.23$ cuantitativamente mejoró, siendo un 5.95% más alta. Las exactitudes de productor y usuario también mejoraron para la clase Q y para la clase NQ la exactitud del productor aumento y la exactitud de usuario disminuyó. El porcentaje de error de omisión y comisión para la clase Q disminuyeron y para la clase NQ el porcentaje de error de omisión disminuyó, pero el de comisión aumentó.
- La exactitud global de la estrategia C cuantitativamente no mejoró, al contrario, disminuyó un 3.85%, pero visualmente representa mejor el fenómeno y no se observa el bandeo como con el método inicial. Los porcentajes de las exactitudes de productor y usuario para la clase NQ disminuyó y aumentó respectivamente, por lo cual los errores de omisión y comisión aumentaron y disminuyeron. Para la clase Q pasa lo contrario la exactitud de productor aumentó y la exactitud de usuario disminuyó. Por lo tanto, los errores de omisión y comisión disminuyeron y aumentaron respectivamente.

Podemos notar que existe una subestimación en la clase quemada y esto es atribuido a la calidad del cubo de datos usado. Como vimos en la sección 4.6.2, sí tuviéramos un cubo de datos de mejor calidad la exactitud aumentaría, por lo cual la hipótesis planteada en dicha sección fue probada.

El método resulta ser una buena propuesta para el estudio de áreas quemadas. Este podría ser utilizado de dos maneras en los estudios de vegetación. Primero, para detectar cambios abruptos en la componente de tendencia a largo plazo dentro de series de tiempo. En segundo lugar, como se demuestra aquí, la estimación de cambios abruptos combinada con el cálculo de índices como el dNBR se puede utilizar para determinar perturbaciones en el ecosistema como áreas quemadas. Además, como lo indica (Dutrieux *et al.*, 2014; Verbesselt *et al.*, 2010, 2012) la fortaleza de BFAST radica en su libre acceso y simplicidad para procesar múltiples años de información satelital, ya que es posible extraer y resumir información para evaluar la ocurrencia de los cambios que ocurren en diferentes ecosistemas.

VI. CONCLUSIONES

Los resultados obtenidos de las simulaciones ilustran que la capacidad de BFAST para detectar cambios dentro de una serie de tiempo está influenciada por el ruido, en este caso de estudio fue causado por la falta de datos de la serie de tiempo.

BFAST puede estimar un punto de cambio correctamente cuando el porcentaje de datos faltantes es menor o igual al 40% y con un valor de $h=0.23$ y puede estimar dos puntos de cambio correctamente a partir de las distancias $l=50$ y $l=70$. Además, usando $h=0.15$ lleva a una sobreestimación de puntos mientras que con $h=0.23$ existe una aparente subestimación y que cuando el porcentaje de datos faltantes dentro de la serie de tiempo aumenta, la precisión al detectar el cambio abrupto correcto disminuye, por lo tanto, el MSE aumenta. Con estos estudios de simulación determinamos que la estimación de puntos de cambio en la serie de NDVI vía BFAST es adecuada siempre que el porcentaje de observaciones faltantes en el pixel no exceda el 40%. Por lo tanto, cuando la serie de tiempo está completa (sin datos faltantes), en los dos escenarios considerados en las simulaciones, BFAST es robusto en la detección correcta de los puntos de cambio, pero deja de serlo cuándo hay cierto porcentaje de datos faltantes dentro de las series de tiempo.

Por otra parte, al combinar el uso de BFAST sobre el cubo de NDVI y calcular el correspondiente dNBR alrededor de los puntos de cambio estimados permitió determinar áreas quemadas en La Primavera en el periodo de 2003 a 2016 en series de tiempo Landsat-7. A pesar de ciertas limitantes que existen en los datos Landsat-7, el algoritmo BFAST puede ser utilizado para el monitoreo de los cambios que ocurren dentro de un ecosistema, así como para identificar áreas quemadas obteniendo una exactitud de identificación de área quemada del 57% cuándo la calidad de los datos es baja y una exactitud de identificación de área quemada mayor al 70% cuándo la calidad de los datos es buena, es decir, el porcentaje de datos es al menos del 40%.

El método expuesto y los resultados obtenidos permiten monitorear la recuperación o recrecimiento de la vegetación en áreas afectadas por incendios, y podría ser utilizada para otros eventos que afecten a la vegetación como plagas.

Sin duda, sería interesante aplicar la metodología desarrollada en otras áreas para confirmar la validez y la utilidad de la misma. También sería de gran interés ampliar el periodo de estudio, pero con otro producto (Landsat-8, SENTINEL, entre otros.). Por ejemplo, si aplicáramos el algoritmo a datos con más frecuencia, como SENTINEL (5 días) la calidad de datos disponibles aumentaría drásticamente ya que no existen limitantes como bandeo, por ello los NA's deberían ser mucho menos y de acuerdo a los resultados obtenidos la detección de puntos de cambio al igual que las áreas quemadas detectadas mejorarían significativamente.

Además, el análisis enriquece el conocimiento previo obtenido sobre la aplicación de BFAST a series de tiempo de imágenes satelitales y enfatiza la posibilidad de utilizar datos Landsat-7 para el análisis de series de tiempo en el estudio de las coberturas, monitoreo forestal y la generación de cartografía temática (Roy *et al.*, 2010; Kennedy *et al.*, 2010; Griffiths *et al.*, 2013; White *et al.*, 2014; Hermosilla *et al.*, 2015), aprovechando su disponibilidad gratuita.

Una propuesta para mejorar el método sería usar BFAST de una manera integrada para analizar series de tiempo de imágenes satelitales de sensores múltiples y para integrarlo con técnicas de fusión de datos, como por ejemplo la fusión de MODIS con imágenes Landsat-7 o SENTINEL con Landsat-7 para combinar altas resoluciones espaciales y temporales, ya que la fusión de datos ha ayudado a mejorar el mapeo de las perturbaciones (Hilker *et al.*, 2009).

REFERENCIAS

- Aronoff, S. (1982). *Classification accuracy: a user approach*, Photogrammetric Engineering and Remote Sensing, 48(8):1299-1307.
- Bai, J., y Perron, P. (2003). *Computation and analysis of multiple structural change models*. Journal of Applied Econometrics, 18(1), 1–22.
- BAER (2003). Burned Area Emergency Response, Remote Sensing Training.
- Congalton, R. G. (1991). *A review of assessing the accuracy of classifications of remotely sensed data*, Remote Sensing of the Environment, 37:35-46.
- Cocke, A. E., Fulé, P. Z. y Crouse, J. E. (2005). *Comparison of burn severity assessments using Differenced Normalized Burn Ratio and ground data*. International Journal of Wildland Fire, 14, pp. 189-198.
- Chen, J., Zhu, X., Vogelmann, J.E., Gao, F. y Jin, S. (2011). *A simple and effective method for filling gaps in Landsat ETM+ SLC-off images*. Remote Sensing of Environment., 115, 1053-1064.
- Chuvieco, E. (1996 y 2001). *Fundamentos de Teledetección espacial*. Edición. RIALP S.A. Madrid, España.
- Chuvieco, E. (1998). *El factor temporal en teledetección: evolución fenomenológica y análisis de cambios*. Revista de teledetección, 10: 1–9.
- Chuvieco, E., Martín, M.P. y Ventura, G., (2002). *Evaluación de imágenes NOAA-AVHRR y Terra-MODIS para cartografía regional de áreas quemadas*. X Simposio Internacional de la Sociedad de Expertos Latinoamericanos en Percepción Remota (SELPER). Cochabamba. Bolivia.
- Chuvieco, E., Giglio, L. y Justice, C. O. (2008). *Global Characterization of Fire Activity: Towards Defining Fire Regimes From Earth Observation Data*. Global Change Biology, 14: 1488-1502.
- DeVries, B., Verbesselt, J., Kooistra, L., y Herold, M. (2015). *Robust Monitoring of Small-Scale Forest Disturbances in a Tropical Montane Forest Using Landsat Time Series*. Remote Sensing of Environment 161: 107–121.
- Díaz-Delgado, R., Lloret, F., y Pons, X. (2003). Influence of fire severity on plant regeneration by means of remote sensing imagery. *International Journal of Remote Sensing*, 24(8), 1751-1763.
- Dutrieux, L. P., Verbesselt, J., Kooistra, L., y Herold, M. (2015). *Monitoring Forest Cover Loss Using Multiple Data Streams, a Case Study of a Tropical Dry Forest in Bolivia*. ISPRS Journal of Photogrammetry and Remote Sensing In press.
- El informador. (2016). *Recuperan hectáreas tras el megaincendio de 2012*. Recuperado de <https://www.informador.mx/Jalisco/Recuperan-hectareas-tras-el-megaincendio-de-2012-20160506-0150.html>.
- Epting, J., Verbyla, D., y Sorbel, B. (2005). Evaluation of remotely sensed indices for assessing burn severity in interior Alaska using Landsat TM and ETM+. *Remote Sensing of Environment*, 96(3-4), 328-339.

- Escuin, S., Navarro, R., y P. Fernández. (2008). *Fire severity assessment by using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) derived from LANDSAT TM/ETM images*. *Int. J. Remote Sensing*, 29:1053-1073.
- Foga, S., Scaramuzza, P. L., Guo, S., Zhu, Z., Dilley, R. D., Beckmann, T., y B. Laue. (2017). *Cloud detection algorithm comparison and validation for operational Landsat data products*. *Remote Sensing of Environment*, 194, 379-390.
- Geerken, R. A. (2009). *An algorithm to classify and monitor seasonal variations in vegetation phenologies and their inter-annual change*. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(4), 422-431.
- Griffiths, P., Linden, S., Van Der Kuemmerle, T., y Hostert, P. (2013). *A pixel-based Landsat compositing algorithm for large area land mapping*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(5), 2088-2101.
- Hermosilla, T., Wulder, M.A., White J.C., Coops, N.C. y G.W. Hobart. (2015). *An integrated Landsat time series protocol for change detection and generation of anual gap-free Surface reflectance composites*. *Remote Sensing of Enviroment* 158, 220-234.
- Hilker, T., Wulder, M.A., Coops, N.C., Linke, J., McDermind, G., Masek, J.G., Gao, F., y White, J.C. (2009). *A new data fusion model for high spatial- and temporal-resolution mapping of forest disturbance based on Landsat and MODIS*. *Remote Sensing of Environment* 113 (8), 1613-1627.
- Huerta, F. M., e Ibarra, J. L. (2014). *Incendios en el bosque la primavera (Jalisco, México): un acercamiento a sus posibles causas y consecuencias*. *Ciencia UAT*, 9(1), 23-32.
- Hyndman, R. J., et al. (2018). *Package "forecast"*. [Online] <https://cran.r-project.org/web/packages/forecast/forecast.pdf>.
- Jamel, D., Barrento, A., Solano, R., y A. Huete. (2015). *MODIS Vegetation Index User's Guide (MOD13 Series)*. Ver. 3.00, June 2015 (collection 6).
- Janssen, L.L.F., y Van der Wel, F. (1994) *Accuracy assessment of satellite derived land cover data: a review*. *IEEE, Photogrammetric Engineering & Remote Sensing*, 60, 419-426.
- Jin S., y Sader., S. (2005). *MODIS time-series imagery for forest disturbance detection and quantification of patch size effects*. *Remote Sensing of Environment* 99(4): 462-470.
- Key, C.H., y Benson, N. (1999). *The Normalized Burn Ratio (NBR): a Landsat TM radiometric measure of burn severity*.
- Key, C. H., y Benson, N. C. (2005). *Landscape assessment: remote sensing of severity, the normalized burn ratio and ground measure of severity, the composite burn index*. *FIREMON: Fire effects monitoring and inventory system* Ogden, Utah: USDA Forest Service, Rocky Mountain Res. Station.
- Key, C.H., y Benson, N.C. (2006). *Landscape assessment (LA) sampling and analysis methods*. USDA Forest Service Gen. Tech. Rep., RMRS-GTR-164-CD.
- Keeley, J. E. (2009). *Fire intensity, fire severity and burn severity: a brief review and suggested usage*. *International Journal of Widlan Fire*, 18: 116-126.

- Kennedy, R. E., Yang, Z. & Cohen, W. B. (2010). *Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr-Temporal segmentation algorithms*. Remote Sensing of Environment 114, 2897-2910.
- Landsat Missions, USGS. (2016). *Landsat 7*. Sección: About Landsat. Recuperado de <https://landsat.usgs.gov/>.
- Landsat Missions, USGS. (2016). *SLC-off Products*. Recuperado de <https://landsat.usgs.gov/slc-products-background>.
- López, M. y Caselles, V. (1991). *Mapping burns and natural reforestation using Thematic Mapper data*. Geocarto International, 6, 31-37.
- Lutes, D., Kane, R. E., Caratti, J. F., Key, C. H., Benson, N. C., Sutherland, S. y L. H. Gnagi. (2006). *Firemon: Fire Effects Monitoring and Inventory System*, Tech. Rep. RMRS-GTR-164-CD, United States Department of Agriculture, Forest Service, Rocky Mountain, Research Station.
- Masek, J. G., Vermote, E. F., Saleous, N. E., Wolfe, R., Hall, F. G., Huemmrich, K. F., Gao, F., Kutler, J., y Lim, T. K. (2006). *A Landsat surface reflectance dataset for North America, 1990-2000*. IEEE Geoscience and Remote Sensing Letters, 3, 68-72.
- Mas, F., Reyes, J., Díaz, J. y Pérez, A. (2003). *Evaluación de la confiabilidad temática de mapas o de imágenes clasificadas: una revisión*. Investigaciones geográficas, (51), 53-72. Recuperado de http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-46112003000200005&lng=es&tlng=es.
- Medio Ambiente y desarrollo Territorial. (s/f). Recuperado de <https://www.arcgis.com/apps/StoryMapBasic/index.html?appid=8d63d2dcd96043fd8337de9be3e3a6b8>.
- Miller, H.J. y S.R. Yool. (2002). Mapping forest post-fire canopy consumption in several overstory types using multi-temporal Landsat TM and ETM data. Remote Sensing of the Environment Environ. 82: 481-496.
- Miller, J.D. y A.E. Thode. (2007). *Quantifying burn severity in a heterogeneous landscape with a relative version of the delta normalized burn ratio (dNBR)*. Remote Sensing of the Environment 109(1):66-80.
- Moritz, S., y Bartz, T. (2017). *ImputeTS: time series missing value imputation in R*. The R Journal, 9(1), 207-218.
- Moritz, S. (2016). *ImputeTS: Time Series Missing Value Imputation*. Recuperado de <http://CRAN.R-project.org/package=imputeTS>. R package version 1.7.
- Moritz, S. (2016). *Package imputeTS*. Recuperado de <http://cran.r-project.org/web/packages/imputeTS/imputeTS.pdf>. R package version 1.7.
- Norton, J.M. (2006). *The use of remote sensing indices to determine wildland burn severity in semiarid sagebrush steppe rangelands using Landsat ETM+ and SPOT 5*. MS Thesis, Idaho State University.

- Normalized Burn Ratio. (2015). Recuperado el 03 de enero de 2018, de http://gsp.humboldt.edu/OLM_2015/Courses/GSP_216_Online/lesson5-1/NBR.html.
- Pereira, J. M. C., et al. (1999). *Spectral characterisation and discrimination of burnt areas*. In Remote sensing of large wildfires. Springer Berlin Heidelberg.
- Pereira, J. M. C. (1999). *A Comparative Evaluation of NOAA/AVHRR Vegetation Indexes for Burned Surface Detection and Mapping*. IEEE Transactions on Geoscience and Remote Sensing, 37: 217-226.
- Purkis, S. J. y Klemas, V. V., 2011. *Remote sensing and global environmental change*. John Wiley y Sons.
- Robinson, J. G. y Bodmer, R. E. (1999). *Toward wildfire management in tropical forests*. Wildfire Manage, 63, 1-13.
- Rouse, J. W., Haas, R. H., Schell, J. A. y D. W. Deering (1973). *Monitoring vegetation systems in the Great Plains with ERTS*, Third ERTS Symposium, NASA SP-351 I, 309- 317.
- Roy, D. P., Boschetti, L. y Trigg, S. N. (2006) *Remote sensing of fire severity: assessing the performance of the Normalized Burn Ratio*. IEEE Geoscience and Remote Sensing Letters, 1, pp. 112-116.
- Roy, D.P., Ju, J., Kline, K., Scaramuzza, P. L., Kovalsky, V., Hansen, M., Loveland, T.R., Vermote, E., y Zhang, C. (2010). Web-enabled Landsat Data (WELD): Landsat ETM+ composited mosaics of the conterminous United States. Remote Sensing of Environment, Vol. 114: pp. 35-49.
- Secretaría de Medio Ambiente y Recursos Naturales (Semarnat). (2000). Programa de Manejo Área de Protección de Flora y Fauna La Primavera.
- Tanase, M., de la Riva, J., y Pérez-Cabello, F. (2011). Estimating burn severity at the regional level using optically based indices. *Canadian Journal of Forest Research*, 41(4), 863-872.
- Trigg, S. y S. Flasse. (2001). *An evaluation of different bi-spectral spaces for discriminating burned shrub-savannah*. International Journal of Remote Sensing, 22: 2641–2647.
- USGS. (1990). *The spatial data transfer standard*. United States Geological Survey, Draft.
- Van, J.W., Root, R.R., Key, C.H. (2004). *Comparison of AVIRIS and Landsat ETM+ detection capabilities for burn severity*. Remote Sens. Environ. 92(3): 397–408.
- Venables, W. N., y Ripley, B. D. (2002). *Modern applied statistics with S*, 4th Edition. Springer-Verlag.
- Velasco, P. (2010). *Tasa de transformación del habitat en el Área Natural Protegida: “Bosque La Primavera”, México, provocada por actividades antropogénicas (incendios) en el periodo: 2005 al 2009*. Universidad de Alcalá, p.23.
- Vermote, E.F. et al. (1997). *Atmospheric correction of visible to middle-infrared EOS-MODIS data over land surfaces: Background, operational algorithm, and validation*, J. Geophys. Res., 102, 17131-17141.
- Verbesselt, J., Robinson, A., Stone, C., y Culvenor, D. (2009). *Forecasting tree mortality using change metrics derived from MODIS satellite data*. Forest Ecology and Management, 258, 1166-1173.

- Verbesselt, J., R. Hyndman, G. Newnham, y D. Culvenor. (2010). *Detecting Trend and Seasonal Changes in Satellite Image Time Series*. *Remote Sensing of Environment* 114 (1): 106–115.
- Verbesselt, J., Hyndman, R., Zeileis, A., y Culvenor, D. (2010). *Phenological change detection while accounting for abrupt and gradual trends in satellite image time series*. *Remote Sensing of Environment*, 114, 2970-2980.
- Verbesselt, J., Zeileis, A., y Herold, M. (2012). *Near real-time disturbance detection using satellite image time series*. *Remote Sensing of Environment*, 123, 98-108.
- Vermote, E. F., Deuze, J. L., Herman, M., y Morcrette, J. J. (1997). *Second simulation of the satellite signal in the solar spectrum, 6S: An overview*. *IEEE Transactions on Geoscience and Remote Sensing*, 35, 675-686.
- Weber, K.T., Seefeldt, S., Moffet, C. y J. Norton. (2008). *Comparing fire severity models from post-fire and pre/post-fire differenced imagery*. *GIScience and Remote Sensing* 45(4):392-405.
- White, J. D., Ryan, K. C., Key, C. C., y Running, S. W. (1996). *Remote sensing of forest fire severity and vegetation recovery*. *International Journal of Wildland Fire*, 6(3), 125-136.
- White J.C., Wulder M. A., Hobart G.W., Luther J.E., Hermosilla, T., Griffiths, P., Coops, N.C., Hall, R.J., Hostert, P., A. Dyk A., y Guindon, L. (2014). *Pixel-Based Image Compositing for Large-Area Dense Time Series Applications and Science*. *Canadian Journal of Remote Sensing*, 40: 192-212.
- Zhang, C., Li, W., y Travis, D. (2007). *Gaps-fill of SLC-off Landsat ETM+ satellite image using a geostatistical approach*. *International Journal of Remote Sensing*, 28, 5103-5122.
- Zhang, X., et al. (2009). *Sensitivity of vegetation phenology detection to the temporal resolution of satellite data*. *International Journal of Remote Sensing* 30 (8), 2061-2074.
- Zeileis, A., Leisch, F., Hornik, K., y Kleiber, C. (2002). *Strucchange: An R Package for Testing for Structural Change in Linear Regression Models*. *Journal of Statistical Software*, 7, 1-38.
- Zeileis, A., Leisch, F., Kleiber, C., y Hornik, K. (2005). *Monitoring structural change in dynamic econometric models*. *Journal of Applied Econometrics*, 20, 99-121.
- Zeileis, A. (2011). *Applied Econometrics with R*. Baltimore-USA: Springer.
- Zhu, Z., y Woodcock, C. E. (2012). *Object-based cloud and cloud shadow detection in Landsat imagery*. *Remote Sensing of Environment*, 118, 83-94.
- Zhu, X., Liu, D., y Chen, J. (2012). *A new geostatistical approach for filling gaps in Landsat ETM+ SLC-off images*. *Remote Sensing of Environment*, 124, 49-60.
- Zhu, Z., y Woodcock, C. E. (2014). *Continuous change detection and classification of land cover using all available Landsat data*. *Remote Sensing of Environment*, 144, 152-171.
- Zhu, Z., Woodcock, C. E., Holden, C., y Yang, Z. (2015). *Generating synthetic Landsat images based on all available Landsat data: Predicting Landsat surface reflectance at any given time*. *Remote Sensing of Environment*, 162, 67-83.

ANEXOS

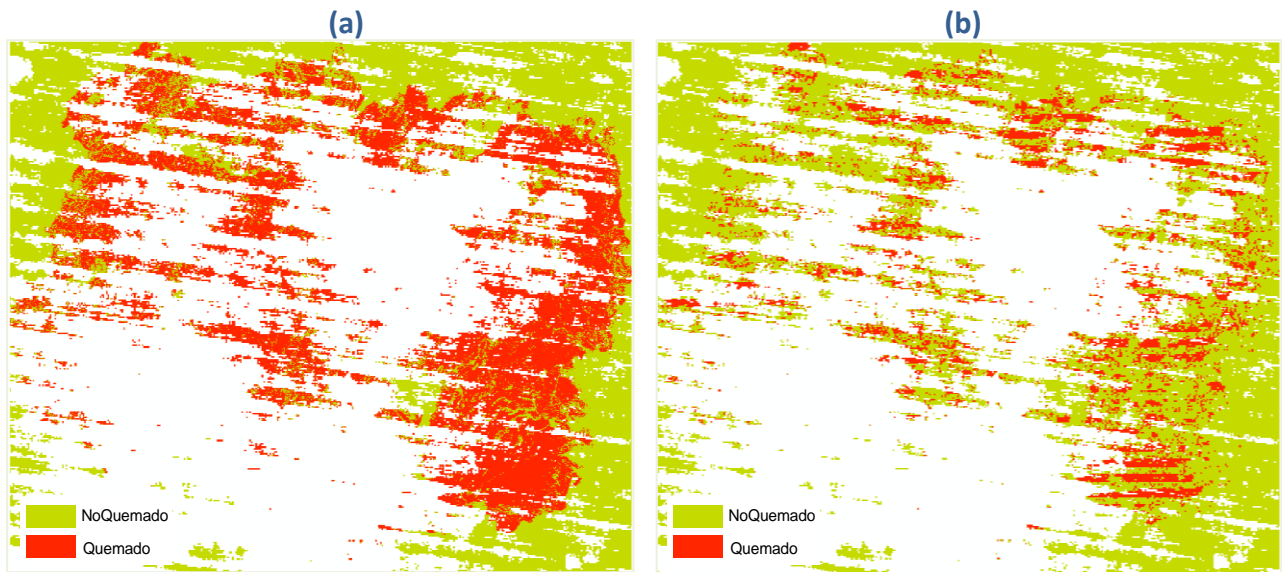


Figura 55. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 2 (método 23_A. I, 1_D. I)

(a) Área quemada 2012 delimitada con RAPIDEYE ya con la máscara aplicada (referencia); (b) Área quemada 2012 obtenida a través del método, utilizando $h=0.15$ (23_A. I, 1_D. I) ya con la máscara aplicada.

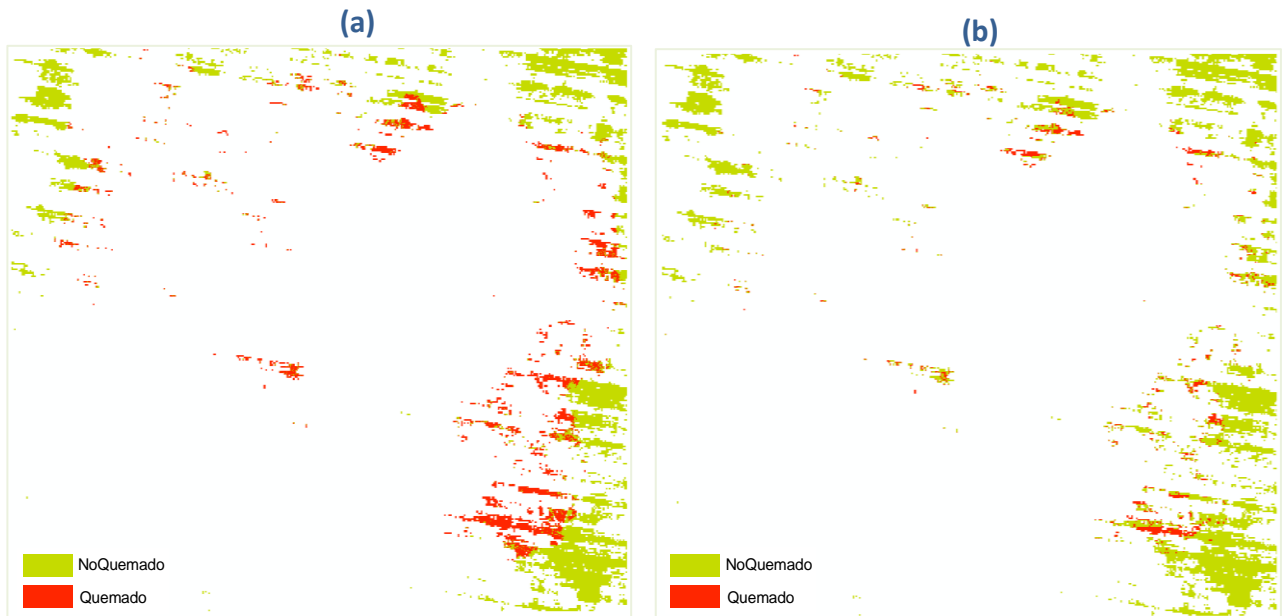


Figura 56. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (método 23_A. I, 1_D. I)

(a) Área quemada 2012 delimitada con RAPIDEYE con la máscara aplicada (referencia); (b) Área quemada 2012 obtenida a través del método, utilizando $h=0.15$ (método 23_A. I, 1_D. I) con la máscara aplicada.

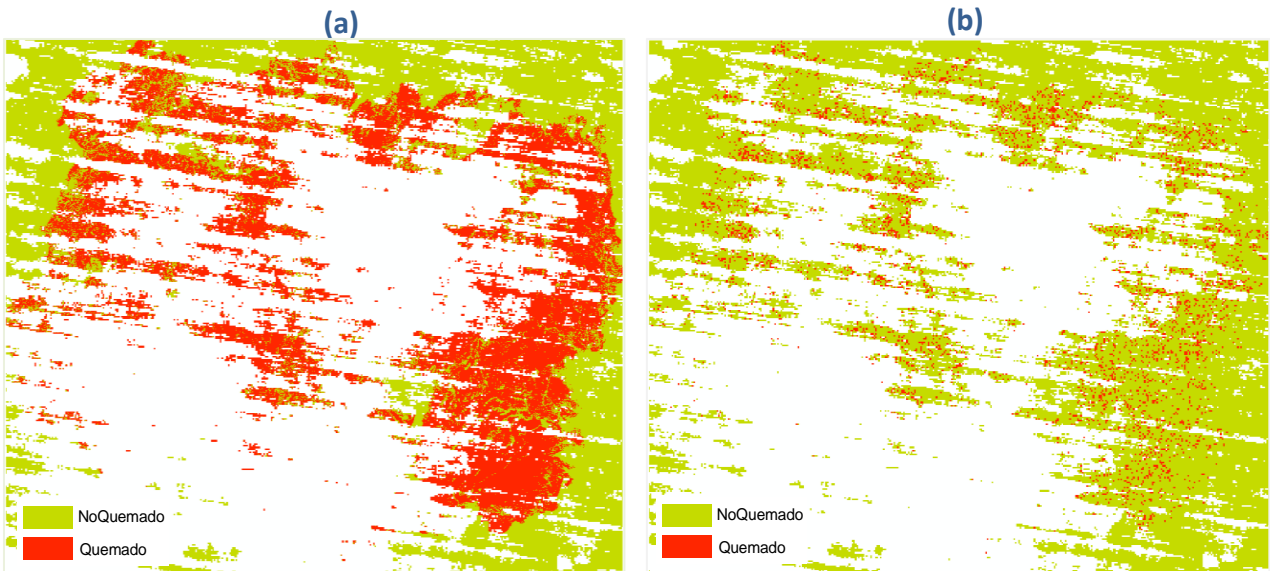


Figura 57. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 2 (Estrategia B)

(a) Área quemada 2012 delimitada con RAPIDEYE con la máscara aplicada (referencia); (b) Área quemada 2012 obtenida a través del método, utilizando $h=0.23$ (Estrategia B) con la máscara aplicada.

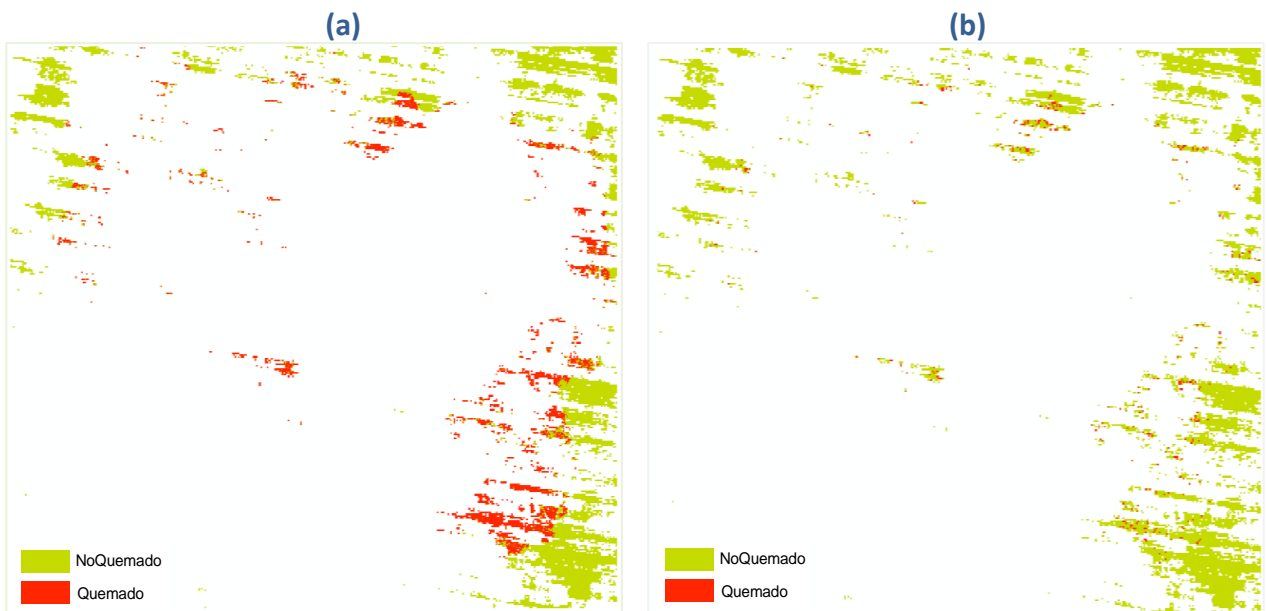


Figura 58. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (Estrategia B)

(a) Área quemada 2012 delimitada con RAPIDEYE con la máscara aplicada (referencia); (b) Área quemada 2012 obtenida a través del método, utilizando $h=0.23$ (Estrategia B) con la máscara aplicada.

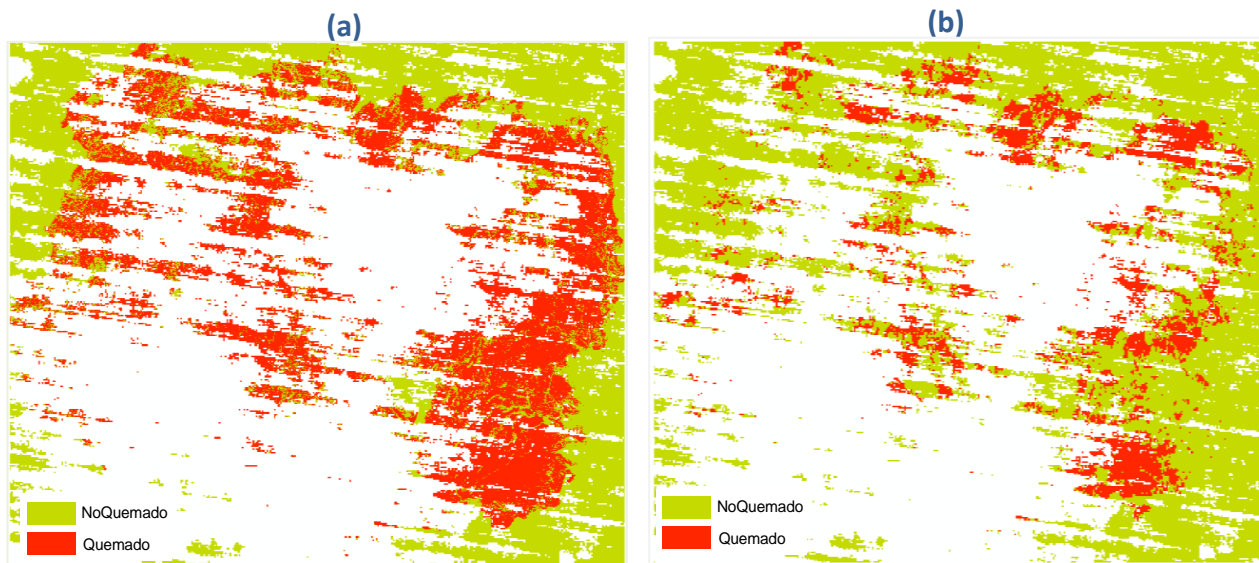


Figura 59. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 2 (Estrategia C)

(a) Área quemada 2012 delimitada con RAPIDEYE con la máscara aplicada (referencia); (b) Área quemada 2012 a través del método, utilizando $h=0.15$ (Estrategia C) con la máscara aplicada.

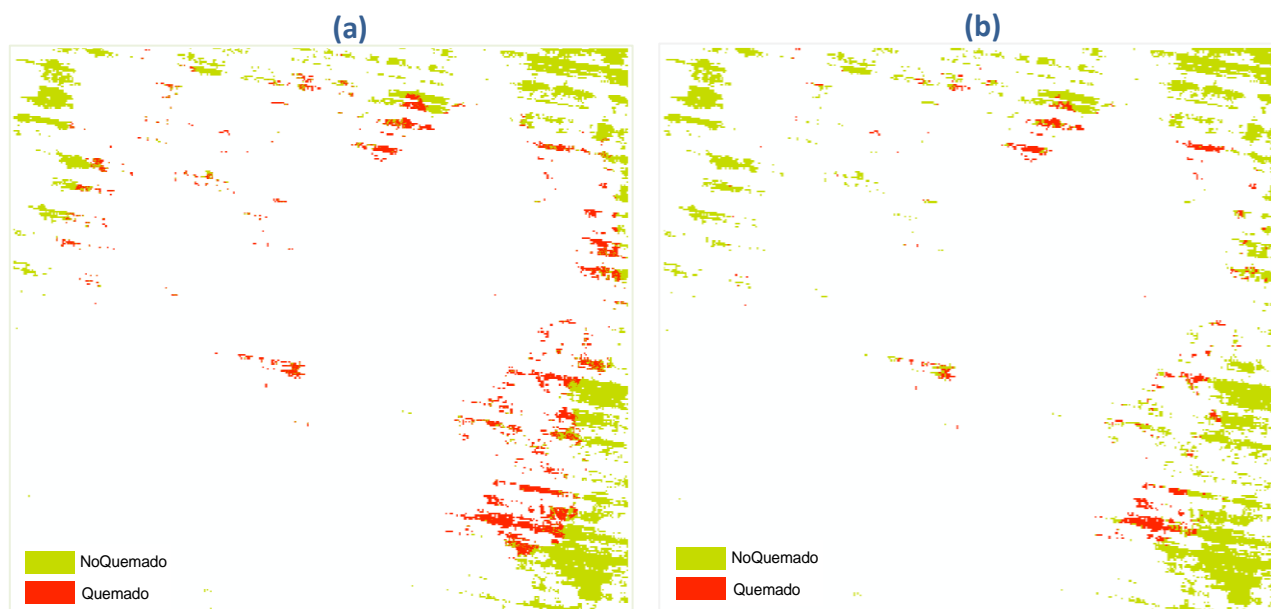


Figura 60. Evaluación de la exactitud del área quemada de 2012 utilizando la máscara del grupo de píxeles 1 (Estrategia C)

(a) Área quemada 2012 delimitada con RAPIDEYE con la máscara aplicada (referencia); (b) Área quemada 2012 obtenida a través del método, utilizando $h=0.15$ (Estrategia C) con la máscara aplicada.