

Detección de Cambios Anómalos mediante Teledetección

Trabajo Fin de Máster

Máster Oficial de Teledetección



Miguel Ángel Belenguer Plomer

Director: Dr. Gustau Camps Valls



Máster Oficial de Teledetección

D./D^a. *Gustau Camps Valls*, Profesor/a del Máster de Teledetección de la Universitat de València

DECLARA: Que la presente Memoria "DETECCIÓN DE CAMBIOS ANÓMALOS MEDIANTE TELEDETECCIÓN", ha sido realizada bajo su dirección por D./D³. Miguel Ángel Belenguer Plomer, y constituye su Trabajo de Fin de Máster, dando el visto bueno para su presentación ante el Tribunal de Trabajo de Fin de Máster que corresponda.

Y para que así conste, firmo la presente en

Burjassot, de de 2016

Índice general

			Pág	ina			
Resi	ımen .			IV			
1.	Introducción						
	1.1.	Motivación y justificación					
	1.2.	Detección de cambios en teledetección					
	1.3.	Estado del arte en detectores de cambios					
		1.3.1.	Técnicas con el píxel como unidad de análisis funda-				
			mental	6			
		1.3.2.	Técnicas con objetos como unidad de análisis	12			
		1.3.3.	Otras unidades de análisis en la detección de cambios	13			
	1.4.	Detectores ACD y EC-ACD					
	1.5.	Objetiv	os	15			
2.	Mater	Materiales y fuentes					
	2.1.	Imágenes multiespectrales empleadas					
		2.1.1.	Detección de una zona forestal quemada mediante				
			Landsat-8	17			
		2.1.2.	Detección del desecado de un lago mediante MODIS	18			
		2.1.3.	Detección de cambios urbanos mediante QuickBird .	19			
		2.1.4.	Detección de cambios en campos de fútbol mediante				
			Sentinel-2	19			
	2.2.	Softwar	e empleado	20			
3.	Metod	lología .		21			
	3.1.	Concepto de cambio anómalo en imágenes					
	3.2.	Proceso general de trabajo					
	3.3.	Detectores ACD					

	3.4.	Detector	res EC-ACD	28
	3.5.	Evaluaci	ón de las detecciones	30
		3.5.1.	Evaluación de la robustez	32
		3.5.2.	Evaluación de la precisión	32
4.	Resulta	ados		34
5.	Discus	ión		10
6.	Conclu	siones		15
7.	Anexos	S		17
8.	Bibliog	grafía		51

Resumen

Este trabajo de fin de máster aborda el problema de la detección automática de cambios anómalos ocurridos en la superficie terrestre mediante imágenes satelitales de la Tierra. Dichos cambios implican cualquier variación fuera de lo típicamente esperado que se produzca en un área determinada del planeta. Su detección es muy importante dentro de las ciencias de la Tierra, ya que en el contexto actual de calentamiento global y cambio climático, presentan una importancia muy elevada en la escala global y local, permitiendo descubrir nuevos efectos generados por las actividades humanas que alteren el medio natural, y también posibles desestabilizaciones a gran escala entre los sistemas terrestres.

En este trabajo se han empleado detectores de anomalías ACD (Anomaly Change Detection) basados en covarianzas, y también las respectivas versiones de contorneado elíptico (Elliptically-Countoured, EC) que extienden esta familia. Estos detectores están basados en el método Reed-Xiaoli, el cuál ha sido ampliamente utilizado en problemas de detección de cambios anómalos. La utilización de estos métodos se ha llevado a cabo en la detección de cambios anómalos reales ocurridos en diferentes lugares de la Tierra, y para la que se han utilizado imágenes multi-espectrales de distintas resoluciones espaciales y espectrales (Landsat-8, MODIS, QuickBird y Sentinel-2), lográndose en la mayoría de casos detecciones con elevada precisión y baja tasa de falsas detecciones. Así, se ha confirmado que, en la mayoría de casos, existe una relación directa entre la resolución espectral de las imágenes empleadas y el acierto en las detecciones de cambios anómalos obtenidas. Además, la reducción de la componente espectral de las imágenes mediante el análisis de los componentes principales (PCA) mejora la todas las detecciones realizadas, al igual que un postprocesado basado en un filtrado espacial.

1. Introducción

La detección de cambios tiene como objetivo identificar diferencias en el estado de un objeto, región o fenómeno mediante su observación en diferentes momentos temporales (Singh, 1989). En este trabajo, los cambios producidos en la superficie terrestre se han diferenciado entre anómalos y regulares, siendo los anómalos las variaciones fuera de lo habitual que se manifiestan en un lugar determinado, y los regulares las que se manifiestan de forma periódica y usual (Theiler y Perkins, 2006). Es decir, un cambio anómalo es cualquier alteración de la escena que esté fuera de lo típicamente esperado, como por ejemplo una inundación de una zona que normalmente siempre se encuentra seca. Por el contrario, un cambio regular es un suceso habitual, que sigue un patrón temporal cíclico bien definido, como por ejemplo, el cambio en el color de parte de la vegetación con el paso de las estaciones. En la presente investigación nos vamos a centrar únicamente en la detección de cambios anómalos en la superficie terrestre.

A continuación, en los siguientes subapartados vamos a tratar la motivación del tema planteado, las ventajas y dificultades que ofrece la teledetección en la detección de este tipo de cambios, el estado del arte de los detectores de cambios en imágenes, los detectores que se van a emplear y los objetivos propuestos en este trabajo de fin de máster.

1.1. Motivación y justificación

La detección de cambios anómalos en la superficie de la Tierra está estrechamente relacionada con uno de los mayores retos actuales de las ciencias de la Tierra, que es la cuantificación y comprensión de los efectos humanos en los sistemas naturales. Igualmente, la detección de este tipo de anomalías tiene un elevado interés dentro de las ciencias de la Tierra, dado que permite revelar posibles desestabilizaciones dentro del sistema terrestre. Esto se debe a que la Tierra está integrada por un conjunto de sistemas naturales a través de los cuales la materia y energía fluyen constantemente, y cualquier variación atípica que se produzca en alguna zona de la

cubierta terrestre es por tanto consecuencia de un desequilibrio entre las relaciones de dichos sistemas, que son la atmósfera, hidrosfera, litosfera y biosfera (Strahler y Strahler, 1989).

Existen cinco principales causas que originan los cambios anómalos en la superficie terrestre (Lambin y Strahler, 1994): cambios naturales en las condiciones climáticas (1), procesos geomorfológicos y ecológicos (2), variabilidad climática interanual (3), alteraciones humanas directas (4) y el efecto invernadero causado por las actividades antropogénicas indirectamente (5). De las cinco causas mencionadas, son las actividades humanas, tanto las directas como las indirectas, las que actualmente generan una mayor desestabilización entre las relaciones naturales de dichos sistemas, y en consecuencia, son estas actividades las principales responsables de la aparición de cambios anómalos en la superficie terrestre. De ahí que exista un creciente interés en desarrollar metodologías que permitan analizar los cambios ocurridos dentro de diferentes temas de estudio de las ciencias de la Tierra. En la figura 1 se encuentran los principales temas de estudio donde la detección de cambios anómalos en la superficie terrestre es una rama de investigación muy importante (Lu et al., 2004). Estos temas se han agrupado en tres esferas: actividades humanas (1), conservación de ecosistemas (2) y riesgos naturales (3).

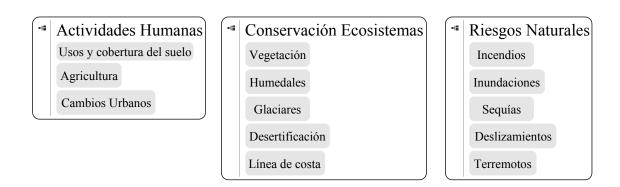


Figura 1: Disciplinas ambientales donde la detección de cambios es muy importante.

Asimismo, en el contexto actual marcado por el calentamiento global debido al efecto invernadero, se espera que la aparición de cambios anómalos se incremente progresivamente a causa de la desestabilización del equilibrio mantenido entre los sistemas terrestres. Esto acarrearía inesperadas consecuencias ambientales, económicas

y sociales, sobre todo teniendo en cuenta que las previsiones demográficas mundiales advierten del crecimiento exponencial de la población mundial, estimándose más de 9 000 millones de habitantes en todo el planeta en el 2050 (Godfray et al., 2010). Por ello, el desarrollo de técnicas que detecten de forma automática y precisa dichos cambios, es una rama de especial interés dentro de las ciencias de la Tierra, puesto que ello permitiría proponer medidas correctoras que eviten las desestabilizaciones mencionadas, antes de que estas sean demasiado graves.

1.2. Detección de cambios en teledetección

Para atacar el problema de la detección de cambios anómalos en la superficie terrestre, la teledetección resulta una aproximación imprescindible, ya que permite detectar los cambios de forma sinóptica en una zona determinada mediante la adquisición de datos en forma de imágenes, con distintas resoluciones espaciales, espectrales y temporales, cuyo formato digital permite procesar dicha información computacionalmente de forma automática, pudiendo identificar cambios anómalos que podrían ser omitidos por los investigadores si no fuera por la existencia de estos datos (Lu et al., 2004; Wu et al., 2015). Esto también permite detectar cambios sobre cualquier lugar del planeta sin la necesidad de desplazarse hasta él, reduciendo así los costes económicos y temporales de la investigación respecto a los estudios realizados con campañas de campo (Radke et al., 2005).

Sin embargo, la detección de los cambios anómalos en teledetección tiene dificultades a causa de la existencia de diversos factores ajenos a la escena observada, siendo estos: el ruido introducido en las imágenes debido a la transmisión/compresión de la señal (1), los movimientos del sensor durante la adquisición de las imágenes (2), los cambios en la iluminación de una imagen respecto a otras anteriores (3), las diferencias entre los ángulos de observación de cada imagen (4), y las variaciones en las condiciones atmosféricas en los momentos de adquisición (5) (Lu et al., 2004; Theiler et al., 2010). Es por ello que antes de aplicar los métodos de detección de cambios entre imágenes, es muy recomendable eliminar los efectos de estos factores mediante el pre-procesado de las imágenes, corrigiéndolas geométricamente, radiométricamente y atmosféricamente. En el Anexo I se amplía la infor-

mación acerca de estas correcciones. Al aplicar dichas correcciones nos aseguramos que los cambios detectados entre las imágenes empleadas dependen exclusivamente de la escena observada, y no de factores externos a ésta. Los factores mencionados dan lugar a cambios regulares debidos al proceso de adquisición de las imágenes. Estos cambios se deben únicamente a variaciones en las imágenes y no a cambios en la superficie observada, haciendo que en los problemas de detección de cambios anómalos en teledetección podamos toparnos con dos tipos de cambios regulares: los de la escena y los de las imágenes.

- Cambios regulares de la escena: Son aquellos que se presentan siguiendo un patrón cíclico en una determinada zona y que por ello su detección carece de importancia dentro de las ciencias de la Tierra. Por ejemplo el cambio estacional producido en los campos de arroz de la Albufera (Valencia), donde en función del mes en que realicemos la observación la escena tendrá un aspecto determinado marcado por el ciclo fenológico del cultivo.
- Cambios regulares debidos a la adquisición de las imágenes: Son los cambios cuyo origen está en la adquisición de las imágenes y no en la escena observada. Son generados por factores externos a la escena que se observa. Dichos factores ya se han mencionado previamente.

En la detección automática de cambios anómalos mediante imágenes satelitales no es posible distinguir entre los cambios anómalos y los regulares debidos a variaciones de la escena, dado que los algoritmos no tienen la capacidad crítica para diferenciar entre cambios de interés y cambios habituales. Por ello, tal y como afirman Lu et al. (2004) es necesario emplear imágenes tomadas en épocas similares del año para que las variaciones intra-anuales no supongan un problema a la hora de detectar las variaciones atípicas. No obstante, la distinción entre los cambios regulares externos a la escena y los cambios anómalos que se pretenden detectar sí que es posible llevarla a cabo con detectores de cambios automáticos. Aunque es uno de los problemas más extendidos en el campo de la detección de cambios anómalos en la superficie terrestre mediante teledetección, siendo este campo un tema principal de investigación desde hace más de tres décadas (Aplin, 2004; Mas, 1999).

1.3. Estado del arte en detectores de cambios

El continuo avance tecnológico en los sensores de adquisición de las imágenes hace que actualmente se sigan desarrollando nuevas técnicas de detección de cambios que permitan trasladar dichas mejoras tecnológicas a un mayor grado de acierto en las detecciones (Chen et al., 2012), y que en la literatura se publiquen numerosas revisiones acerca de estas técnicas (Coppin et al., 2004; Hussain et al., 2013; Lu et al., 2004; Radke et al., 2005; Tewkesbury et al., 2015). La mayoría de los autores coinciden en que no existe un detector de cambios universal que se pueda emplear en todos los casos, ya que cada problema específico requiere la selección de un método concreto que se adapte a las características particulares de los datos y que consiga los mejores resultados. Pero esta selección no es algo sencillo, ya que se ha de seleccionar la técnica que permita detectar mejor los cambios existentes, con la mayor objetividad posible (Hussain et al., 2013; Lu et al., 2004). Por ello, en este trabajo hemos investigado los principales métodos de detección de cambios, a fin de seleccionar el que más nos conviene.

Dentro de las diferentes técnicas de detección de cambios entre imágenes, Tewkesbury et al. (2015) diferencian entre la unidad de análisis mediante la cual se procede a realizar la detección, y los métodos de comparación de las imágenes. La unidad de análisis es la unidad espacial de referencia en la que se basan las comparaciones de las imágenes para detectar los cambios ocurridos entre estas. La gran mayoría de las técnicas utilizan el píxel como unidad de análisis fundamental en la detección de cambios. No obstante, la utilización de esta unidad de análisis tiene críticas dada su baja idoneidad a la hora de detectar cambios con imágenes de alta resolución espacial (Very High Resolution, VHR), ya que pueden originarse errores en la detección debido al incremento de la densidad de la información, haciendo que se produzcan numerosas falsas detecciones en forma de píxeles sueltos (Chen et al., 2012; Niemeyer et al., 2008). Por ello, en este tipo de imágenes se suele emplear una unidad de análisis basada en los objetos propios de la imagen (Hussain et al., 2013). A pesar del dominio del píxel como unidad de análisis y del incremento de la utilización de los objetos de las imágenes, existen más unidades mediante las cuales se puede aplicar diferentes métodos para detectar cambios. En la figura 2 se observa de forma esquemática el estado actual de los métodos de detección de cambios entre imágenes, los cuales se van a ampliar detalladamente a continuación.

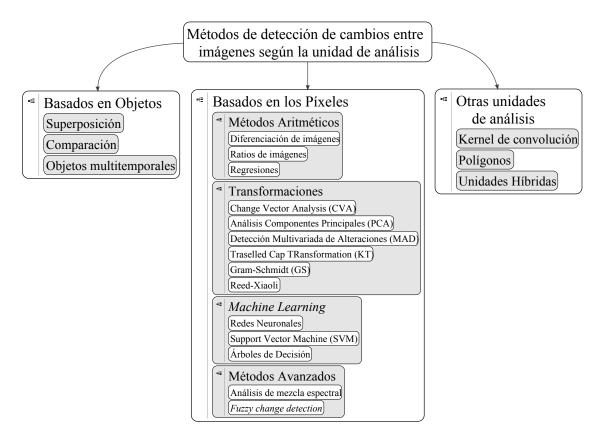


Figura 2: Esquema de los tipos de unidades de análisis y métodos para detectar cambios entre imágenes.

1.3.1. Técnicas con el píxel como unidad de análisis fundamental

El píxel es el elemento fundamental de la imagen (Fisher, 1997), y se ha empleado desde los inicios de la teledetección como el núcleo básico de análisis digital para detectar variaciones en las intensidades de sus valores que se debiesen a cambios en la escena observada (Tewkesbury et al., 2015). Sin embargo, la utilización del píxel como unidad de análisis no siempre es la más adecuada, como en el caso de las imágenes VHR. Chen et al. (2012) argumentan en contra de la utilización del píxel como unidad de análisis porque tiene una libertad de comparación limitada entre las imágenes, pudiendo detectar únicamente si se han producido cambios en una imagen clasificada, observando las clases de la misma, o también comparando el valor de los píxeles, lo cual afirma que no constituye un marco de trabajo adecuado

para la detección de cambios. A pesar de estas críticas, los detectores de cambios basados en el píxel como unidad de análisis son los más numerosos. A continuación se incluyen los cuatro principales grupos que emplean el píxel como unidad de análisis fundamental en la detección de cambios en imágenes.

- 1.3.1.1. Métodos aritméticos Son aquellos que se basan en operaciones aritméticas (suma, resta, multiplicación y división) entre imágenes bitemporales, ya sea operando con los valores de reflectividad de las imágenes, o con productos derivados como son los índices de vegetación, variables biofísicas estimadas como el índice de la superficie foliar (LAI), o cualquier característica derivada (Tewkesbury et al., 2015). Son los métodos más utilizados por los usuarios que quieren detectar cambios entre imágenes dada su sencillez (Lu et al., 2004). Los principales tipos de métodos aritméticos para la detección de cambios son:
 - Diferenciación entre imágenes: Es un método simple basado en la resta entre imágenes bitemporales, cuyos resultados son de fácil interpretación, ya que cuando un píxel no ha cambiado, el valor de la imagen obtenida será de 0. Aunque su principal problema es que la imagen de diferencias obtenida expresa valores absolutos, lo cual hace que el mismo valor pueda significar cambios distintos en función del tipo de cobertura que sea (Hussain et al., 2013). Además este método es muy sensible a los cambios regulares debidos a la adquisición de las imágenes (Radke et al., 2005).
 - Ratios entre imágenes: Se basa en la obtención de un ratio dividiendo banda a banda las imágenes bitemporales. En el caso de que la intensidad de un píxel no haya cambiado nada, se obtendrá un valor de uno. Su principal ventaja es que reduce los efectos de los cambios regulares debidos a la adquisición de las imágenes, aunque proporciona un resultado con una distribución no normal (Lu et al., 2004).
 - Análisis de regresión entre imágenes: La regresión entre imágenes se emplea para la detección de cambios estableciendo relaciones que permiten estimar los valores de la imagen de la segunda fecha mediante la utilización de una función de regresión, siendo la imagen del error de estimación un buen indicador de

las anomalías. Mediante este método también se consigue reducir los efectos de los cambios regulares debidos a la adquisición de las imágenes, aunque precisa del desarrollo de una función de regresión con elevado acierto antes de la implementación de la detección de cambios, y no es un buen método a la hora de detectar cambios sutiles (Coppin et al., 2004; Lu et al., 2004).

- 1.3.1.2. Transformaciones Los métodos basados en transformaciones se basan en la reducción de los datos redundantes de las bandas espectrales de las imágenes, y en enfatizar la información derivada en los diferentes componentes obtenidos de las transformaciones para llevar a cabo la detección de los cambios (Lu et al., 2004). Dentro de la clase de transformaciones se incluyen los siguientes métodos:
 - Change Vector Analysis (CVA): El CVA se basa en la idea que los píxeles con cambios residen en una localización diferente respecto a los de no cambios dentro del espacio de representación espectral de los datos (Im y Jensen, 2005). Por lo consiguiente, el método interpreta el cambio basándose en la magnitud y dirección de los datos aislados, permitiendo así analizar de forma múltiple bandas espectrales de las imágenes bitemporales (Hussain et al., 2013; Tewkesbury et al., 2015). Su principal ventaja es la capacidad de procesar cualquier número de bandas espectrales y detectar los cambios de forma detallada, aunque no es adecuado para indagar acerca de la trayectoria del cambio en lo relativo a los tipos de cubiertas terrestres (Lu et al., 2004).
 - Análisis de Componentes Principales (PCA): El análisis de los componentes principales (PCA) es una transformación de los datos en un nuevo conjunto de componentes con la máxima varianza, que permite reducir la redundancia de los datos. Para ello se utiliza la matriz de covarianza de los datos, de la cual se obtienen los autovectores (eigenvectors), que muestran la dirección predominante de los conjuntos de los datos de forma ortogonal entre sí, y los autovalores (eigenvalues), que expresan la variación de esos datos en la correspondiente dirección del espacio caracterizado por el autovector. El PCA consigue resumir la información espectral seleccionando los componentes principales (PC) con mayor varianza (mayor autovalor), que son los que más información contienen. El PCA se ha utilizado en detección de cambios entre imágenes, ya que

asume que los datos multitemporales tienen una elevada correlación, y que la información de los cambios puede ser destacada en los nuevos componentes principales (Lu et al., 2004). Sin embargo posee la misma desventaja que el CVA, ya que se trata de un método que no permite identificar las características de las coberturas que han cambiado (Hussain et al., 2013; Lu et al., 2004). En este trabajo el PCA se va a utilizar para reducir la dimensión espectral de las imágenes seleccionadas, y comprobar si al comprimir dicha información en pocos componentes principales la detección de los cambios ocurridos en la escena mejora o por el contrario empeora.

- Detección Multivariada de Alteraciones (MAD): La detección multivariada de alteraciones (MAD) propuesta por Nielsen et al. (1998) crea una combinación lineal de las intensidades de todos los canales de la imagen más antigua y posteriormente de la más reciente, con lo que se obtiene una nueva banda de diferencias entre ambas imágenes que se denomina MAD. Una de las principales propiedades de las MAD es la ortogonalidad, debido a que cada componente canónica es ortogonal a las otras. La otra propiedad característica de las MAD es la invariancia frente al escalado: se trata de un detector invariante ante cualquier efecto lineal sobre la imagen.
- Ineal multi-banda que fue presentado por Kauth y Tomas en 1976 y permite analizar la estructura espacial de los datos (Hussain et al., 2013). Es similar al PCA, siendo la única diferencia que, mientras el PCA depende de la imagen de la escena, las transformaciones que realiza el KT son independientes de la escena de la imagen, haciendo que la detección de los cambios se base únicamente en tres variables de la escena: brillo, verdor y humedad (Hussain et al., 2013; Lu et al., 2004).
- Gram-Schmidt (GS): Es un método desarrollado a partir de la modificación del KT que ortogonaliza los vectores espectrales tomados directamente de imágenes bitemporales, y que al igual que el KT, produce tres componentes estables correspondientes al brillo, verdor y humedad, y otro componente del cambio ocurrido (Lu et al., 2004).

- Reed-Xiaoli: Los métodos Reed-Xiaoli (RX) fueron propuestos por Reed y Yu (1990), y son métodos muy efectivos y famosos en el campo de la detección de cambios anómalos en la teledetección (Wu et al., 2015). Estos métodos se basan en matrices de covarianzas y en la distancia de Mahalanobis para detectar los cambios entre imágenes. A partir de estos métodos se han obtenido diferentes métodos, como la familia de detectores ACD (Anomaly Change Detection) propuesta por Theiler y Perkins (2006), y la versión de contornos elípticos EC (Ellipticaly-contoured) propuesta por Theiler et al. (2010). En este trabajo de fin de máster se ha optado por emplear este conjunto de detectores para la detección de cambios anómalos en la superficie terrestre dadas las mencionadas ventajas.
- 1.3.1.3. Métodos de *Machine Learning*: El aprendizaje automático, más conocido como *Machine Learning*, es una rama de la inteligencia artificial (AI) que permite a los algoritmos *aprender* por su cuenta a partir de una información no estructurada de los datos, la cual es obtenida mediante ejemplos. Así, los algoritmos de estos métodos pueden mejorar el conocimiento de un problema de forma automática conforme están siendo utilizados (Chan *et al.*, 2001). Tradicionalmente estos métodos han sido empleados en problemas de clasificación, no obstante, tal y como ya se ha dicho, también pueden utilizarse para detectar cambios. Dentro de la clase de *Machine Learning* se incluyen los siguientes métodos de detección de cambios:
 - Redes Neuronales: Las redes neuronales (Artificial Neural Network, ANN), son algoritmos no paramétricos que no realizan asunciones acerca de la distribución y dependencia de los datos. Estos algoritmos aprenden con los datos de entrenamiento y construyen relaciones entre las imágenes previas y posteriores a los cambios (Hussain et al., 2013). Una vez hecho esto, la red neuronal es aplicada a la totalidad de la imagen para así obtener el mapa de cambios (Dai y Khorram, 1999). Su principal limitación es que necesita mucho tiempo de entrenamiento para que la detección de los cambios sea óptima (Lu et al., 2004).
 - Support Vector Machine (SVM): El clasificador SVM es una técnica estadísti-

ca no paramétrica que busca un hiperplano que permita separar de la forma más óptima posible los datos de una clase del resto. Para ello reproyecta previamente los datos en un espacio de dimensionalidad superior. Una de sus principales ventajas es que es capaz de manejar conjuntos de datos de entrenamiento pequeños y lograr un elevado acierto en la detección (Camps-Valls et al., 2004). Sin embargo se trata de un clasificador con un coste computacional muy elevado para un elevado número de muestras.

- Árboles de decisión: Los árboles de decisión también son algoritmos no paramétricos que no asumen asunción acerca de la distribución e independencia de los datos. Estos algoritmos construyen una estructura en forma de árbol en el que cada nodo representa un ensayo con un número de valores de atributos, cada rama representa un resultado de la prueba, y las hojas del árbol representan clases o distribuciones de estas (Hussain et al., 2013). Las reglas de clasificación se basan en el análisis de valores de atributos, pudiéndose emplear para clasificar casos desconocidos una vez ya está construido.
- 1.3.1.4. Métodos avanzados Esta clase está compuesta por los métodos que no encajan en los tres grupos anteriores. Los métodos incluidos en esta clase son los siguientes:
 - Análisis de mezcla espectral: Este método se basa en la teoría de los píxeles mezclados, lo que indica que cada píxel está compuesto de una proporción relativa de características dominantes que tienen propiedades espectrales relativamente constantes (Versluis y Rogan, 2010; Vila y Barbosa, 2010). Esta técnica mide la reflectividad de un píxel en cada banda espectral como una combinación de las reflectividades de los componentes dominantes, ponderados proporcionalmente según su superficie (Rogan et al., 2002), permitiendo obtener mapas de abundancia de los componentes dominantes de los píxeles. Así se puede emplear dicho método para obtener medidas cuantitativas de las principales características presentes en el área de estudio y en consecuencia detectar los posibles cambios ocurridos.
 - Fuzzy change detection: Los métodos fuzzy o difusos en castellano, han sido

tradicionalmente aplicados en teledetección para clasificación de fenómenos naturales distribuidos de forma incierta, en los que no hay límites claros entre los objetos geográficos, y existe una gran heterogeneidad dentro de una clase (Lizarazo y Barros, 2010). Estos métodos son apropiados en la detección de cambios en los casos en que la selección de un umbral que distinga entre cambio y no cambio sea difícil (Hussain *et al.*, 2013).

1.3.2. Técnicas con objetos como unidad de análisis

Los objetos de las imágenes son grupos de píxeles de estas que representan objetos significativos de la escena (Chen et al., 2012). Constituyen una unidad de análisis en la detección de cambios entre imágenes reciente, que se engloba dentro del concepto de Objetos Geográficos Basados en el Análisis de la Imagen (GEOBIA) (Hay y Castilla, 2008). Según Hussain et al. (2013) existen tres métodos primordiales que utilizan estos objetos como unidad de análisis para la detección de cambios:

1.3.2.1. Superposición de objetos de la imagen Los objetos identificados en una imagen son superpuestos en la otra imagen sobre la que se pretende detectar los cambios ocurridos frente a la primera, delimitando así el marco de trabajo de dicha detección (Listner y Niemeyer, 2011). Sin embargo el principal inconveniente de este método son los cambios geométricos ocurridos entre las imágenes, los cuales pueden generar que la superposición de los objetos no sea del todo precisa a la posición exacta de los cambios (Tewkesbury et al., 2015).

1.3.2.2. Comparación de objetos de las imágenes La diferencia esencial de este método frente al anterior es que los objetos son delimitados en ambas imágenes de forma independiente, y seguidamente se comparan dichos objetos en busca de posibles cambios. Su principal ventaja es que se puede analizar cómo ha variado el tamaño, la forma e incluso la clase de los cambios detectados en los objetos (Chen et al., 2012; Listner y Niemeyer, 2011). No obstante, si una de las imágenes no se ha pre-procesado correctamente y posee cambios regulares debidos a la adquisición de las mismas, esto puede ocasionar problemas de co-registro entre los objetos, aunque no se hayan producido cambios reales en la escena (Tewkesbury et al., 2015).

1.3.2.3. Objetos de las imágenes multitemporales A diferencia de los otros dos métodos, en este los objetos son identificados empleando varias imágenes multitemporales, las cuales se han concatenado previamente. Su principal ventaja es que al considerar todas las imágenes, se reduce notablemente la fuente de error asociada a los cambios regulares debidos al proceso de adquisición de las imágenes. Aunque este método también presenta limitaciones, principalmente debido a variaciones en el tamaño y la forma de los objetos, lo que impide que estos puedan ser comparados fácilmente, haciendo que los cambios más pequeños puedan ser generalizados y no tenidos en cuenta durante la segmentación de los objetos (Tewkesbury et al., 2015).

1.3.3. Otras unidades de análisis en la detección de cambios

La detección de cambios en teledetección se basa en la comparación de imágenes, la cual se puede realizar en la actualidad empleando diversas unidades de comparación diferentes al píxel y a los objetos de las imágenes. Estas unidades según Tewkesbury et al. (2015) son el kernel de convolución, los polígonos de la imagen y la unidad híbrida. A continuación se detalla cada una de estas unidades con mayor grado de detalle.

1.3.3.1. Kernel de convolución Un kernel de convolución es una matriz con un tamaño definido por el usuario, donde se considera el entorno del píxel central de dicha matriz, el punto (x, y), para realizar diversas operaciones por toda la imagen, dado que el kernel de convolución se va desplazando una vez ha realizado la operación determinada. La utilización del kernel de convolución como unidad de análisis permite incluir información de parte del contexto espacial de las imágenes en la detección de cambios (Tewkesbury et al., 2015). Esta adición de información permite filtrar parte del posible ruido de las imágenes y afinar la detección de los cambios (Bruzzone y Prieto, 2000). No obstante, uno de los problemas del kernel de convolución como unidad de análisis es que a menudo operan con una escala fija en la imagen, y no existe un umbral que determine el tamaño óptimo de esta escala (Warner, 2011). Por lo tanto, el uso de un kernel con un tamaño no adecuado puede generar límites borrosos entre las zonas de cambio y de no cambio, e incluso no detectar los cambios más pequeños (Tewkesbury et al., 2015).

1.3.3.2. Polígonos de la imagen Son agrupaciones de píxeles menos detalladas que los objetos de las imágenes. Los polígonos comenzaron a utilizarse en el ámbito de los Sistemas de Información Geográfica (SIG), y de forma paulatina se empezaron a emplear en la detección de cambios entre imágenes de diferentes momentos temporales mediante una superposición de los polígonos, de forma similar que los métodos que emplean los objetos de las imágenes como unidad de análisis fundamental. Su principal ventaja es que son una unidad de análisis con un amplio potencial en la detección de cambios, aunque esta detección únicamente de limita a la escala espacial de los vectores de los polígonos (Bouziani et al., 2010).

1.3.3.3. Unidad híbrida Las unidades de análisis híbridas son conocidas en la literatura como aquellas que mezclan más de una unidad de análisis en el proceso de detección de cambios. Por ejemplo, la combinación de píxeles con objetos basados en clasificadores y en post-clasificadores, para así afinar el acierto en la detección de cambios (Aguirre-Gutiérrez et al., 2012).

1.4. Detectores ACD y EC-ACD

En este trabajo hemos optado por emplear la familia de cuatro detectores ACD (Anomaly Change Detection) propuestos por Theiler y Perkins (2006), y la versión con contornos elípticos EC (Elliptically-countoured) que extiende estos detectores (Theiler et al., 2010), siendo en total ocho los detectores de anomalías empleados, los cuales explotan como unidad básica de análisis el píxel y la covarianza espectral de las imágenes. Los detectores de la familia ACD complementan el método Reed-Xiaoli (RX) propuesto por Reed y Yu (1990), el cual ha sido ampliamente utilizado en múltiples investigaciones con excelentes resultados en la detección de cambios anómalos entre imágenes hiperespectrales (Ma et al., 2010; Niu y Wang, 2016; Wu et al., 2015; Zare-Baghbidi et al., 2015). Así, tanto el método RX como el resto de detectores de la familia ACD y EC-ACD, se basan en la distancia de Mahalanobis para hallar los píxeles de la imagen posterior al cambio que más han variado su valor respecto a la imagen previa al cambio. Lo que permite distinguir entre los cambios anómalos que estamos interesados en detectar y los cambios regulares debidos al

proceso de adquisición de las imágenes, solventando así el problema de la detección de los cambios regulares debidos a la adquisición de las imágenes. Dicha distinción se basa en que los cambios regulares debidos a la adquisición de las imágenes se dan en toda la escena, a diferencia de los cambios anómalos, que se concentran en una pequeña parte de la misma, lo que genera que los cambios anómalos se encuentren en los extremos de las distribuciones (Longbotham y Camps-Valls, 2014; Theiler et al., 2010).

Sin embargo el principal inconveniente de la familia ACD es que asume que los píxeles con cambios anómalos se pueden detectar mediante una distribución normal o Gaussiana, lo que no siempre es cierto (Longbotham y Camps-Valls, 2014; Zare-Baghbidi et al., 2015). Por ello, Theiler et al. (2010) propusieron la aplicación de un modelo que ajustase los contornos de las distribuciones de las detecciones de los cambios a la distribución de los datos, para así detectar los cambios anómalos ocurridos de una forma más eficiente. Este método se conoce como Contorneado Elíptico (EC) y complementa la familia de detectores ACD generando la versión EC de cada uno de estos métodos, la familia EC-ACD. Esto permite generar una mayor libertad para modelar las distribuciones de detección de los datos en los extremos de estos, ya que es en los extremos de la distribución donde se dan las diferencias más notables entre los cambios regulares y los anómalos (Longbotham y Camps-Valls, 2014).

1.5. Objetivos

El objetivo principal de este trabajo es estudiar la detección de cambios anómalos en la superficie terrestre con los métodos de la familia ACD y EC-ACD, y aplicarlos extensamente en imágenes multiespectrales de diferentes resoluciones espaciales
y espectrales en cuatro casos reales de cambios anómalos ocurridos en la superficie
terrestre. Con la finalidad de obtener una detección óptima de los cambios ocurridos en dichos casos. Este objetivo general se desarrolla en los siguientes objetivos
específicos:

- 1. Observar la relación entre el número de bandas de las imágenes y el tipo de cambio: Los métodos seleccionados funcionan mejor cuanta más información espectral tienen las imágenes empleadas, de ahí que en otros estudios se hayan utilizado principalmente con imágenes hiperespectrales. No obstante, un objetivo de este trabajo es comprobar su robustez ante problemas más exigentes en cuanto a resolución espectral.
- 2. Examinar los resultados obtenidos con cada método empleado: La finalidad de este objetivo es detectar si de los ocho métodos que se van a emplear, existe un detector que siempre obtenga mejores resultados que el resto o, por el contrario, si en cada problema específico es un detector diferente el que obtiene mejores resultados.
- 3. Analizar la invariabilidad de los métodos a los cambios regulares: Uno de los motivos determinantes acerca de la selección de detectores de cambios realizada es que, a diferencia de otros métodos, son muy robustos frente a los cambios regulares debidos a la adquisición de las imágenes. Para analizar dicha robustez se va a detectar un mismo ejemplo de cambio con las mismas imágenes, corregidas atmosféricamente y sin corregir.
- 4. Reducir la componente espectral de las imágenes: Esta reducción se va a realizar mediante el análisis de los componentes principales (PCA), que permite resumir la información espectral de las imágenes en pocos componentes principales (PC). Así, en cada caso de detección se van a realizar pruebas en diferentes experimentos, en los que se va a variar el número de PC para detectar los cambios anómalos existentes, en lugar de emplear las imágenes originales. La finalidad de este objetivo es determinar si al emplear dichos componentes se consigue mejorar las detecciones logradas con las imágenes originales.
- 5. Estudiar los efectos del filtrado de las imágenes de las detecciones: Por último, se va a analizar si, al filtrar espacialmente las imágenes de las detecciones de cambios anómalos con un filtro de moda, se logra reducir las falsas detecciones y mejorar la precisión en la detección.

2. Materiales y fuentes

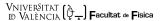
Los materiales empleados en este trabajo son imágenes de diferentes zonas de la superficie terrestre obtenidas por diversos sensores multiespectrales, y también el software necesario para el procesado de las imágenes, representación de los resultados y redacción de la presente memoria de trabajo de fin de máster. A continuación se detalla la información acerca de las imágenes y el software empleado.

2.1. Imágenes multiespectrales empleadas

Las imágenes que se han empleado en este trabajo son multiespectrales de diversas zonas de la superficie terrestre, cuyas bandas espectrales están dentro de la región solar del espectro electromagnético. Estas han sido adquiridas por distintos sensores: Landsat-8, MODIS, QuickBird y Sentinel-2. En el Anexo II se encuentran los enlaces a las webs oficiales de los sensores, donde se puede acceder a las características técnicas de cada uno de ellos. Las zonas mostradas por dichas imágenes son ejemplos de lugares donde se han producido cambios anómalos, siendo estos un incendio forestal en los municipios de Quesada y Huesa (Jaén, España), el desecado del lago Poopó (Oruro, Bolivia), unos cambios urbanos ocurridos en Denver (Colorado, EEUU) y unas variaciones en unos campos de fútbol de la ciudad deportiva del Valencia C.F. de Paterna (Valencia, España), respectivamente. Dichos cambios alteran de diferentes formas las signaturas espectrales de las zonas que los sufren, lo que va a permitir analizar la precisión de los métodos de detección seleccionados en cambios con características muy diferentes entre sí, mediante imágenes de diferentes características. A continuación se detalla la información sobre cada una de estas imágenes y cambios ocurridos.

2.1.1. Detección de una zona forestal quemada mediante Landsat-8

Las imágenes Landsat-8 fueron tomadas por el sensor OLI, y únicamente se han empleado ocho bandas espectrales con una resolución espacial de 30 m cada una de ellas, descartando así la banda pancromática. Dos de las cuatro imágenes fueron



tomadas el 29 de julio de 2014 y las dos restantes el uno de agosto de 2015. Para detectar los cambios ocasionados por el incendio que quemó cerca de 10 000 Ha en julio de 2015 (figura 3).

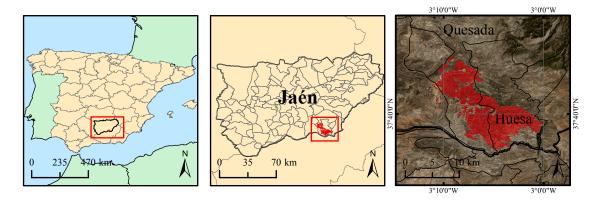


Figura 3: Localización de la zona incendiada en los municipios de Quesada y Huesa en julio de 2015.

El motivo de emplear dos imágenes de cada fecha es porque de cada momento se ha obtenido una imagen de reflectividades en la superficie con los efectos atmosféricos corregidos y otra de reflectividades en el techo de la atmosfera sin corregir dichos efectos, para así poder lograr el objetivo específico de analizar la invariabilidad de los métodos frente a los cambios regulares, concretamente los efectos provocados por la atmosfera. Las imágenes han sido adquiridas desde el portal de descargas *Earth Explorer*¹ del Servicio Geológico de los Estados Unidos (USGS).

2.1.2. Detección del desecado de un lago mediante MODIS

Las imágenes empleadas son las del producto MOD09A1, que se trata de una composición de las reflectividades de la superficie terrestre de ocho días, con siete bandas espectrales y una resolución espacial de 500 m. Estas imágenes se han utilizado para detectar el desecado del lago Poopó en Bolivia a finales de 2015. Este lago era el segundo más grande de agua salada de Bolivia, con una superficie de aproximadamente 2 300 km² (figura 4). Las imágenes seleccionadas para la detección del desecado han sido del cuatro de octubre de 2015 y del 20 de febrero de 2016. Se han adquirido desde el sistema de información y datos de observación de la Tierra

¹http://earthexplorer.usgs.gov/

EOSDIS de la NASA².

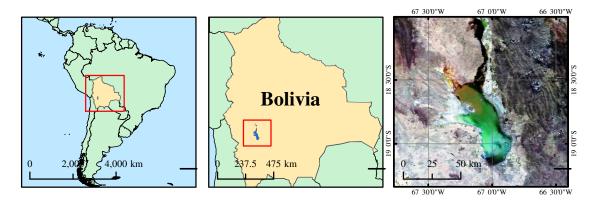


Figura 4: Localización de la zona que ocupaba el lago Poopó antes de su desecado casi completo a finales de 2015.

2.1.3. Detección de cambios urbanos mediante QuickBird

Las imágenes QuickBird empleadas muestran la reflectividad en el techo de la atmósfera en cuatro bandas espectrales con una resolución espacial de 2,4 m. La escena que muestran es una parte de la ciudad de Denver (EEUU) en la que se produjeron una serie de cambios urbanos entre 2002 y 2008 (figura 5). Así, las fechas de adquisición de las imágenes son el 17 de julio de 2002 y el ocho de agosto de 2008. Dichas imágenes han sido suministradas por la empresa líder mundial en imágenes de alta resolución Digital Globe³, dentro del convenio de colaboración con el Laboratorio de Procesado de Imágenes (IPL) de la Universitat de València⁴.

2.1.4. Detección de cambios en campos de fútbol mediante Sentinel-2

Por último, las imágenes de Sentinel-2 utilizadas también muestran la reflectividad en el techo de la atmosfera, pero en 10 bandas espectrales diferentes, siendo el inconveniente de estas bandas que su resolución espacial varía entre los 10 y 20 m dependiendo de la banda espectral de que se trate. La escena seleccionada en las imágenes ha sido la ciudad deportiva del Valencia C.F. situada en Paterna (figura 6), donde en el mes de mayo de 2016 ha habido variaciones en los céspedes de los

²http://http://reverb.echo.nasa.gov/reverb/

³http://https://www.digitalglobe.com/

⁴http://http://isp.uv.es/

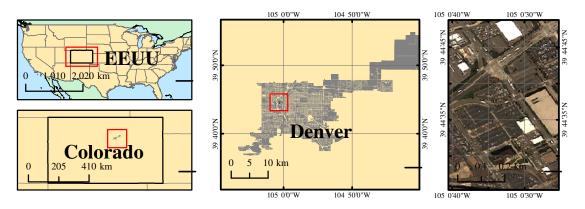


Figura 5: Localización de la zona con cambios urbanos de Denver entre 2002 y 2008.

diferentes campos de fútbol debido a las tareas de mantenimiento del mismo. Las fechas de las imágenes seleccionadas han sido el uno y 26 de mayo de 2016, y se han obtenido del servidor de descargas de la Agencia Espacial Europea $(ESA)^5$.



Figura 6: Localización de los campos de fútbol de la ciudad deportiva del Valencia C.F.

2.2. Software empleado

Para la elaboración de la presente investigación ha sido necesario emplear el programa MatlabTM, donde se han programado todos los métodos de detección de cambios anómalos seleccionados. La programación de estos métodos de detección de cambios en Matlab se proporciona de forma libre mediante una demo ilustrativa que contiene todo el código desarrollado en esta investigación, y que asegura la reproducibilidad de los resultados obtenidos ⁶. Además, en la realización de la presente in-

⁵https://scihub.copernicus.eu/

 $^{^6}$ http://isp.uv.es/soft_classification.html

vestigación también se ha empleado el sistema de información geográfica ArcGISTM, para representar cartográficamente los resultados de las detecciones obtenidas, y elaborar la imagen que incluya las zonas que han sufrido cambios anómalos reales (verdad terreno) mediante una fotointerpretación manual a partir de las imágenes adquiridas, la cual será necesaria para evaluar las detecciones de los métodos. Finalmente, en la redacción del presente documento final del trabajo de fin de máster se ha utilizado el programa LATEX.

3. Metodología

En este apartado de metodología se va a profundizar en el concepto de cambio anómalo, y cómo detectarlo empleando imágenes multiespectrales, además de explicar el proceso general de trabajo que se ha seguido en la investigación. Además se van a mostrar los detectores de la familia ACD y también los EC-ACD. Por último se va a explicar las diferentes evaluaciones que se han realizado a las detecciones logradas.

3.1. Concepto de cambio anómalo en imágenes

En la introducción de este trabajo ya se ha explicado la diferencia entre los cambios anómalos y los regulares. En esta sección se va a profundizar en el concepto matemático que define a los cambios anómalos, en lo cual se basan los métodos seleccionados para detectar únicamente las variaciones anómalas. A fin de plasmar correctamente el concepto de cambio anómalo entre imágenes se ha empleado una parte de las imágenes QuickBird de la ciudad de Denver en la que el cambio anómalo producido es la construcción de un nuevo edificio (figura 7). La imagen previa al cambio es la imagen $I(t_1)$ y la posterior $I(t_2)$. En la figura 8 se muestra las imágenes de las cuatro bandas espectrales de las dos imágenes QuickBird de la figura 7.

Mediante un análisis visual de la figura 8 se aprecian los píxeles afectados por el cambio anómalo mencionado, la nueva edificación, ya que son los píxeles que mayores reflectividades registran en todas las bandas de $I(t_2)$. Sin embargo, un análisis visual

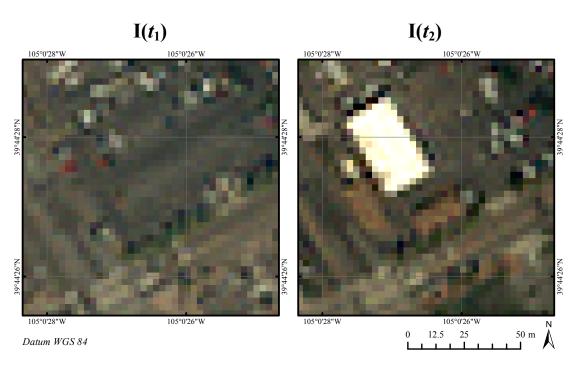


Figura 7: Imágenes RGB de color verdadero de $I(t_1)$ y de $I(t_2)$.

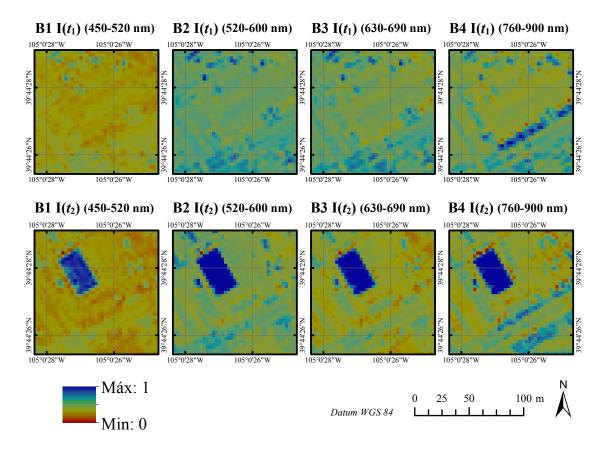


Figura 8: Reflectividades de las bandas espectrales de $I(t_1)$ e $I(t_2)$.

no permite diferenciar los cambios regulares debidos al proceso de adquisición de las imágenes, lo que puede llevar a cometer errores de interpretación de los cambios ocurridos en la escena. Por ello, la mejor forma de detectar los cambios anómalos es mediante una gráfica de dispersión que relacione los valores de todos los píxeles entre las bandas de cada imagen.

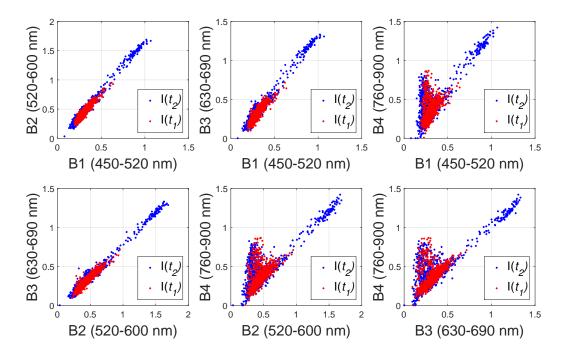


Figura 9: Dispersión de datos de $I(t_1)$ e $I(t_2)$ entre sus bandas espectrales.

En la figura 9 se observa claramente que al proyectar los datos de todas las bandas espectrales de ambas imágenes en el espacio existente entre estas, se consigue aislar los píxeles afectados por cambios anómalos de los afectados por cambios regulares. Los anómalos son los que más se alejan del conjunto de los datos, mientras que los regulares están muy próximos a dicho conjunto. Esto es a causa de que los cambios regulares debidos al proceso de adquisición de las imágenes afectan a la totalidad de la escena observada, mientras que los anómalos solo a una pequeña parte de esta. De esta forma, tal y como sugieren Longbotham y Camps-Valls (2014), se observa en la figura 10 que al sustraer mediante una resta los valores de las bandas de la imagen previa al cambio a los de la las bandas de la imagen posterior al cambio, los píxeles de la imagen que han sufrido un cambio anómalo se concentran en los extremos de las distribuciones de los datos de cada banda espectral.

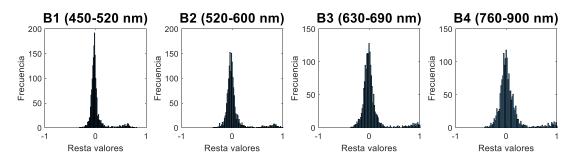


Figura 10: Histogramas de las restas resultantes de las bandas espectrales de $I(t_2)$ menos $I(t_1)$.

La tarea de los detectores de cambios anómalos es simplemente revelar la localización de los píxeles más aislados del resto del conjunto de datos sin confundirse con el resto de píxeles de la imagen. Es en este principio en el que se basan los diferentes métodos de detección de cambios anómalos entre imágenes que se van a emplear en este trabajo, y que se van a explicar en detalle en los siguientes apartados.

3.2. Proceso general de trabajo

A continuación se muestra de forma esquemática los diferentes pasos que se han seguido para llevar a cabo la detección de cambios anómalos en la superficie terrestre mediante imágenes satelitales de una determinada zona, siendo la imagen $I(t_1)$ la previa al cambio y la $I(t_2)$ la posterior (figura 11).

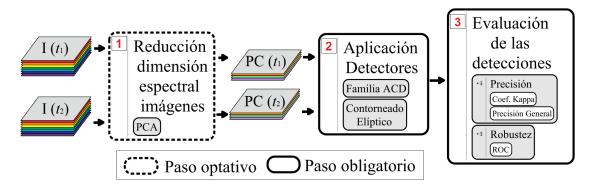


Figura 11: Proceso general de trabajo.

Así el primer paso es reducir el volumen del tamaño de la información de las bandas espectrales de las imágenes, siempre y cuando sea necesario, ya que este no es un paso obligatorio en el proceso de detección. Seguidamente se aplican los diferentes

métodos de detección seleccionados, los detectores ACD y EC-ACD. Finalmente se evalúan las detecciones obtenidas por cada método mediante la generación de las curvas ROC (*Receiver Operating Characteristic*), las cuales permiten evaluar la robustez de las detecciones, y también el cálculo del coeficiente de Kappa y la exactitud global, de la detección y de la no detección, lo que permite evaluar la precisión de las detecciones. Este proceso de trabajo será repetido en cada caso de detección que se realice, estando definido cada uno de los casos por las imágenes $I(t_1)$ y $I(t_2)$ empleadas.

3.3. Detectores ACD

La familia de detectores lineales ACD (Anomaly Change Detection) se basan en el método Reed-Xiaoli (RX) propuesto por Reed y Yu (1990), el cual utiliza la distancia de Mahalanobis entre los píxeles que no han sufrido cambios (background) y los que sí, para detectar los segundos (Camps-Valls et al., 2011, pág. 73). De esta forma, dados dos píxeles \mathbf{x} , \mathbf{y} , los cuales se corresponden con el mismo píxel de una escena observada en momentos temporales distintos, siendo el píxel \mathbf{x} el correspondiente con la imagen $\mathbf{I}(t_1)$ y el píxel \mathbf{y} con la imagen $\mathbf{I}(t_2)$. La familia de detectores ACD se centra en detectar si el píxel \mathbf{y} ha sufrido algún cambio anómalo respecto al \mathbf{x} . La detección de cambios anómalos de la familia ACD para cada píxel es dada por la siguiente expresión:

$$\mathcal{A}(\mathbf{x}, \mathbf{y}) = \xi_z - \beta_x \xi_x - \beta_y \xi_y \tag{1}$$

donde $\xi_z = \mathbf{z} \mathbf{C}_z^{-1} \mathbf{z}^{\mathsf{T}}$, $\xi_x = \mathbf{x} \mathbf{C}_x^{-1} \mathbf{x}^{\mathsf{T}}$, $\xi_y = \mathbf{y} \mathbf{C}_y^{-1} \mathbf{y}^{\mathsf{T}}$, siendo $\mathbf{z} = [\mathbf{x}, \mathbf{y}] \in \mathbb{R}^{2d}$, y se tienen las matrices de covarianza $\mathbf{C}_z = \mathbf{Z}^{\mathsf{T}} \mathbf{Z}$, $\mathbf{C}_x = \mathbf{X}^{\mathsf{T}} \mathbf{X}$, $\mathbf{C}_y = \mathbf{Y}^{\mathsf{T}} \mathbf{Y}$, $\mathbf{Z} = [\mathbf{X}, \mathbf{Y}] \in \mathbb{R}^{2d}$ y los parámetros β_x y $\beta_y \in \{0, 1\}$. Los parámetros β_x y β_y fueron introducidos por Theiler y Perkins (2006) con la finalidad de obtener diferentes algoritmos que complementasen al RX, el cual es el método precursor del resto de detectores que se van a analizar en este trabajo. En la tabla 1 se muestran los algoritmos de detección de cambios anómalos parametrizados con β_x y β_y .

Para explicar mejor las diferencias entre los cuatro métodos de detección de

Tabla 1: Familia de detectores ACD.

Tipo de detector	β_x	β_y
RX	0	0
Chronochrome $(\mathbf{y} \mathbf{x})$	0	1
Chronochrome $(\mathbf{x} \mathbf{y})$	1	0
Hyperbolic ACD	1	1

cambios anómalos vistos en la tabla 1, se han realizado cuatro simulaciones diferentes en las que las matrices \mathbf{X} e \mathbf{Y} de cada simulación contienen 100 datos en dos dimensiones, siendo los valores de ambas matrices exactamente idénticos a excepción de 20 datos que se han variado a propósito de simular cambios anómalos ocurridos entre ambas matrices. El objetivo de estas cuatro simulaciones es representar en el espacio bidimensional de los datos los valores de la matriz \mathbf{Y} , junto a las distribuciones de las detecciones obtenidas con los diferentes métodos de la familia ACD y así observar de qué forma se realiza la distinción entre los datos con cambios anómalos y el background en cada tipo de detector (figura 12). Dichas simulaciones de cambios se asocian a diferencias en el escalado lineal (a), no lineal (c), en el sesgo (a, d) y en el cambio de signo de los datos (b).

El método RX es el más sencillo de todos los de la familia ACD, vistos en la tabla 1, dado que para obtener la detección, únicamente tiene en cuenta la concatenación de \mathbf{x} e \mathbf{y} en $\mathbf{z} = [\mathbf{x}, \mathbf{y}]$ y la matriz conjunta de \mathbf{X} e \mathbf{Y} , $\mathbf{Z} = [\mathbf{X}, \mathbf{Y}]$. Se observa en la figura 12 cómo las detecciones de dicho método permiten diferenciar los datos con cambios anómalos del resto de forma muy evidente en el ejemplo a), el cual es linealmente separable. Sin embargo en el resto de ejemplos no se consigue aislar la totalidad de los datos con cambios del resto sin cometer errores en la detección. En el caso del método Chronochrome ($\mathbf{y}|\mathbf{x}$), se muestra cómo las detecciones en los mismos ejemplos consiguen resultados similares en la detección correcta de los datos con cambios anómalos. Sin embargo, se observa cómo las distribuciones de las detecciones son notablemente diferentes a las del método RX, dado que a diferencia de este método, el Chronochrome ($\mathbf{y}|\mathbf{x}$) resta a la detección la similitud con la matriz \mathbf{Y} . Las detecciones del método Chronochrome ($\mathbf{x}|\mathbf{y}$), el cual resta a la detección obtenida la similitud con la matriz \mathbf{X} , no consiguen aislar de forma adecuada los datos con cambios del resto de los datos ni en el ejemplo a), el cual es el único

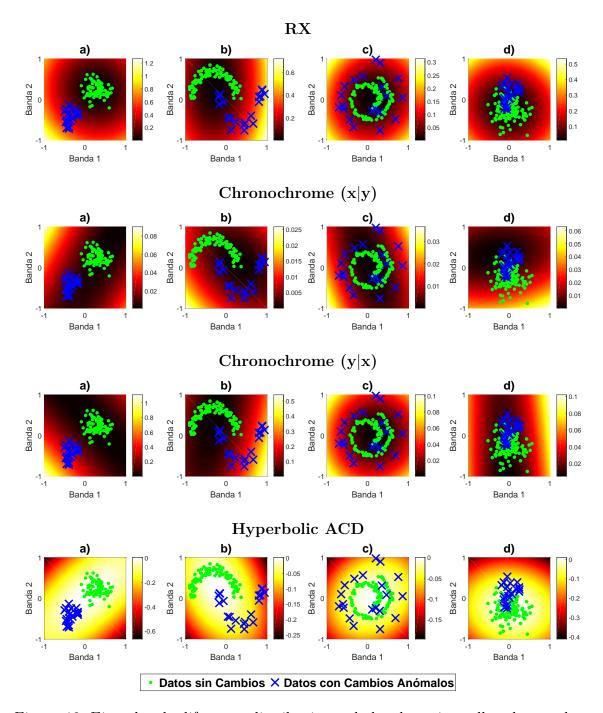


Figura 12: Ejemplos de diferentes distribuciones de las detecciones llevadas a cabo por los métodos ACD en ejemplos sintéticos.

linealmente separable por completo. No obstante, se aprecia que en el ejemplo d) la distribución de detección formada se centra más en los datos con cambios que el resto de métodos. Por último, el método Hyperbolic ACD, que resta a la detección las similitudes con las matrices \mathbf{X} e \mathbf{Y} , obtiene detecciones menos acertadas que en el resto de métodos, dado que las distribuciones no distinguen adecuadamente entre los datos. El inconveniente de estos cuatro métodos es que asumen que los cambios

anómalos existentes en la matriz \mathbf{Y} respecto a \mathbf{X} tienen una distribución normal o Gaussiana, lo que realmente sucede en pocas ocasiones (Longbotham y Camps-Valls, 2014).

3.4. Detectores EC-ACD

La versión de contornos elípticos de la familia de métodos ACD fue propuesta por Theiler et al. (2010) con la finalidad de eliminar la asunción de Gaussianidad a las distribuciones de las detecciones de cambios. Para ello dicha versión aplica un modelo que ajusta los contornos de las distribuciones de las detecciones de los cambios a la distribución de los datos, para así detectar los cambios anómalos ocurridos de una forma más eficiente. Este método se conoce como Elliptically-Contoured (EC), o Contorneado Elíptico y complementa a la familia de detectores ACD generando la versión EC de cada uno de estos métodos. Esto permite generar una mayor libertad para modelar las distribuciones de los datos en los extremos de estos, ya que es en los extremos de la distribución donde se dan las diferencias más notables entre los cambios regulares y los anómalos. La formulación para aplicar el modelo EC en la familia de métodos ACD que proponen Theiler et al. (2010) es la siguiente:

$$\mathcal{A}_{EC}(\mathbf{x}, \mathbf{y}) = (2b + \nu) \log \left(1 + \frac{\xi_z}{\nu - 2} \right)$$

$$-\beta_x (b + \nu) \log \left(1 + \frac{\xi_x}{\nu - 2} \right)$$

$$-\beta_y (b + \nu) \log \left(1 + \frac{\xi_y}{\nu - 2} \right)$$
(2)

donde b es el número de bandas espectrales de las imágenes empleadas y ν controla la forma de la distribución de la detección. En los casos en que $\nu \to \infty$ la detección se aproxima a una distribución Gaussiana, y en los que $\nu \to 2$ la distribución diverge, contorneando los bordes de la distribución a los datos.

Para analizar la versión EC de los métodos de la familia ACD, en la figura 13 se han plasmado las detecciones de estos nuevos métodos en los mismos ejemplos que se han mostrado las detecciones de los métodos de la familia ACD anteriores.

Para ello el valor de ν se ha ajustado empíricamente en el rango $[0, 10^5]$.

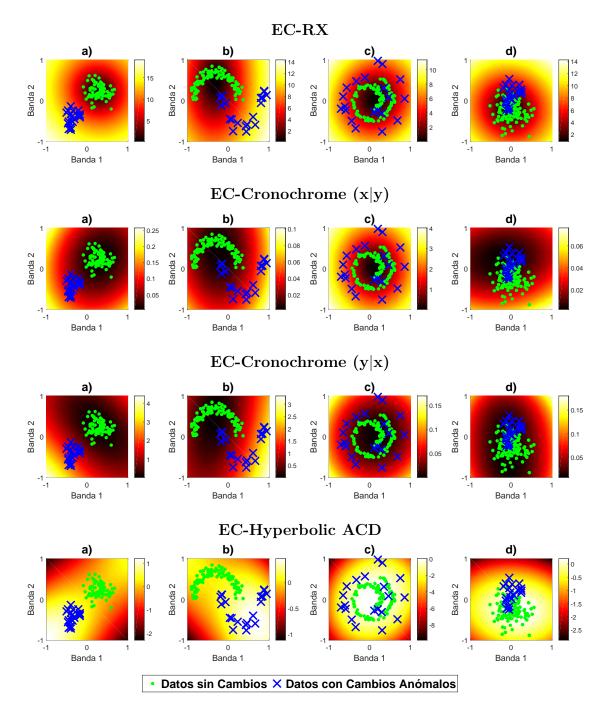


Figura 13: Ejemplos de diferentes distribuciones de las detecciones llevadas a cabo por los métodos EC-ACD en ejemplos sintéticos.

En la tabla 2 se muestran los valores de ν empleados en las detecciones de los diferentes ejemplos de la figura 13, donde se muestran las detecciones de cambios anómalos obtenidas por los métodos EC-RX, EC-Chronochrome ($\mathbf{y}|\mathbf{x}$), EC-Chronochrome ($\mathbf{y}|\mathbf{x}$) y EC-Hyperbolic ACD, respectivamente. Además, en dicha

tabla también se aprecia cómo la mayoría de los valores de ν son muy próximos a dos, lo que significa que en la mayoría de detectores y ejemplos la distribución óptima en la detección de los cambios anómalos diverge de la Gaussianidad. A excepción de los métodos EC-Chronochrome $(\mathbf{y}|\mathbf{x})$ y $(\mathbf{x}|\mathbf{y})$, los cuales dependiendo de qué ejemplo concreto, el valor óptimo de ν se incrementa notablemente respecto al resto, pudiendo destacar el valor de ν del ejemplo d) con el método EC-Chronochrome $(\mathbf{y}|\mathbf{x})$, dado que es donde el valor ν más se aleja de dos y por lo tanto la distribución de su detección mostrada en la figura 13 se asemeja mucho a una distribución normal o Gaussiana. Esto explica que la distribución de este ejemplo concreto con el método EC-Chronochrome $(\mathbf{y}|\mathbf{x})$ en la figura 13 se asemeje mucho a la detección del método Chronochrome $(\mathbf{y}|\mathbf{x})$ de la figura 12, el cual asume la Gaussianidad en la distribución igual que el resto de métodos de la familia ACD.

Tabla 2: Valores ν óptimos figura 13.

Ejemplo	a)	b)	c)	d)
EC-RX	2,07	2,07	2,07	2,07
EC-Chronochrome $(\mathbf{y} \mathbf{x})$	$3,\!27$	2,60	$23,\!64$	343,06
EC-Chronochrome $(\mathbf{x} \mathbf{y})$	$13,\!22$	$13,\!22$	2,07	67,34
EC-Hyperbolic ACD	2,60	2,31	2,07	2,31

Respecto a las ventajas del método EC, en la figura 13 se aprecia como los métodos EC-ACD obtienen distribuciones mejor ajustadas a los datos que los métodos ACD de la figura 12 a excepción de los casos en los que el valor ν óptimo es demasiado elevado dada la distribución Gaussiana de los datos, en los que la detección con los métodos EC es igual a la familia ACD. El ajuste de las distribuciones de los métodos EC-ACD permite que los métodos Chronochrome ($\mathbf{x}|\mathbf{y}$) e Hyperbolic ACD consigan contornos de detección que se ajusten mejor a los datos que sin la versión EC, en los que dichos métodos no realizaban un ajuste adecuado.

3.5. Evaluación de las detecciones

La evaluación de las detecciones de cambios anómalos realizadas por los métodos de detección vistos es una parte crucial del presente trabajo, ya que además de evaluar las detecciones de los diferentes métodos, la evaluación es necesaria para obtener una imagen binaria de *cambio* y *no cambio* de la escena, a partir de la imagen de detecciones resultante de la aplicación de los métodos de detección de cambios, de los que se obtiene una imagen que muestra la probabilidad de cada píxel de estar afectado por un cambio anómalo. Para encontrar el umbral óptimo que permita discriminar entre píxeles con cambios y sin cambios es preciso evaluar la robustez de la detección como se va a mostrar a continuación en la figura 14.

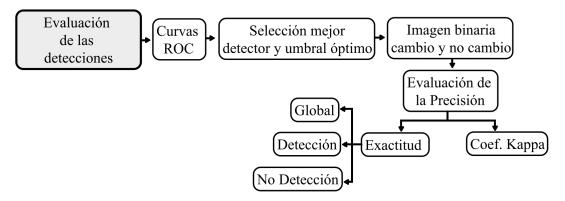


Figura 14: Procedimiento evaluación de las detecciones.

Una vez obtenida la imagen binaria de cambio y no cambio mediante la evaluación de la robustez con la curva ROC, ya se podrán aplicar los métodos de evaluación referentes a la precisión, que son complementarios a los de robustez, y son la exactitud global, la de la detección, de la no detección y también el coeficiente de Kappa, el cual permite diagnosticar el efecto del azar en las detecciones. Sin embargo, para poder aplicar tanto los métodos de evaluación de robustez y de precisión es necesario tener etiquetados una parte de los píxeles que conforman la escena observada, siendo estos los píxeles de test, los cuales no pueden ser los mismos con los que se han entrenado los métodos de detección, los de entrenamiento. Estos píxeles de test, del mismo modo que los de entrenamiento, están conformados por píxeles con cambios anómalos y sin cambios. La diferencia frente a los de entrenamiento es que los de test se emplean para comparar con los píxeles con la misma ubicación en la imagen obtenida en la detección si los resultados coinciden. Por contra, los de entrenamiento sirven para entrenar los métodos de detección. La obtención de los píxeles de test y de entrenamiento se ha llevado a cabo mediante una fotointerpretación manual de los cambios ocurridos, generando así una imagen de verdad terreno de los cambios anómalos en cada uno de los casos de detección propuestos. A continuación se va a explicar con mayor detalle los métodos empleados para evaluar la robustez y precisión de las detecciones, y las características de ambos tipos de evaluación.

3.5.1. Evaluación de la robustez

La evaluación de la robustez se emplea en problemas que implican una sola clase, como es la detección de cambios. Esta medida tiene en cuenta el número de detecciones correctas frente al de detecciones erróneas, y se obtiene mediante la curva ROC (Receiver Operating Characteristic). Esta curva permite cuantificar el balance entre la proporción de detecciones correctas y la proporción de falsas alarmas. Para ello, en cada caso de detección se ha empleado el 2% de los píxeles de las imágenes para testear y el 1% para entrenar cada uno de los detectores. En la tabla 3 se muestra el número exacto de píxeles de test y entrenamiento utilizados en cada caso de detección.

Tabla 3: Píxeles de test y entrenamiento empleados en cada caso de detección.

Casos de estudio	Número de píxeles		
Casos de estadio	Entrenamiento	Test	Imagen Total
Incendio de Quesada y Huesa	4528	9055	452760
Desecado del Lago Poopó	655	1245	65526
Cambios urbanos en Denver	450	900	45000
Cambios en campos de fútbol de Paterna	262	524	26208

El cálculo de estas curvas permite seleccionar el umbral idóneo para distinguir entre cambio y no cambio, y así rechazar la detección de píxeles dudosos en base al umbral que mayor tasa de detecciones correctas consiga, sin comprometer el número de falsas detecciones. La forma de comparar la robustez de diferentes detecciones con las curvas ROC es mediante el cálculo del área bajo la curva (*Area Under the Curve, AUC*). Dicha área tendrá un valor más elevado conforme el rendimiento de la detección sea mayor, siendo el valor máximo de uno.

3.5.2. Evaluación de la precisión

La evaluación de la precisión se suele emplear en problemas que conllevan más de una clase, como son los de clasificación. No obstante, dicha evaluación también se puede aplicar en este trabajo, ya que la detección de cambios se puede comprender como una clasificación binaria entre lo que ha variado y lo que no. Así, la evaluación de la precisión de las detecciones se puede definir como el grado en el que la imagen de detección de cambios obtenida, coincide con los cambios reales ocurridos sobre la superficie (Olofsson et al., 2013). En la literatura existen dos medidas principales, la exactitud global (Overall Accuracy) y el Coeficiente de Kappa (Liu et al., 2007).

- Exactitud global: La exactitud global es el índice más simple y popular empleado en teledetección para evaluar la precisión de las detecciones realizadas (Liu et al., 2007). Este se basa en dividir el número de píxeles de test que se han detectado correctamente entre el número total de los píxeles de test (Camps-Valls et al., 2011, pág. 62). Dicho índice es global y no indica de qué manera la exactitud se reparte entre las diversas categorías individuales. Por lo que también se ha calculado la exactitud de las detecciones y de las no detecciones, que son el resultado de la división del número de píxeles con cambios de la imagen binaria de detecciones entre el número de píxeles con cambios de la imagen de verdad terreno, y el número de píxeles detectados sin cambios entre el número de píxeles sin cambios de la verdad terreno, respectivamente.
- Coeficiente de Kappa: Fue propuesto por Cohen en 1960, y comenzó a aplicarse ampliamente en temas de teledetección en la década de 1980, siendo en la actualidad uno de los índices de precisión más utilizados en la evaluación de resultados (Liu et al., 2007). Este coeficiente determina el efecto del azar en las detecciones realizadas mediante la medición de la diferencia entre la exactitud lograda en la detección obtenida y la casualidad de obtener una detección correcta con un detector aleatorio. El valor de máxima precisión es de uno y el de la mínima de cero. Se define con la siguiente ecuación:

$$\kappa = \frac{N \sum_{i=1}^{r} x_{ij} - \sum_{i=1}^{r} (x_{i+} * x_{+j})}{N^2 - \sum_{i=1}^{r} (x_{i+} * x_{+j})}$$
(3)

donde r es el número de filas en la matriz de confusión, la cual es una tabla de doble entrada que confronta los valores de los cambios con los valores del mapa de detecciones, x_{ij} es el número de observaciones en el elemento de la fila i y la columna j, x_{i+} y x_{+j} son el total de observaciones en la fila i y la

columna j, respectivamente, y N es el número total de observaciones de toda la matriz de confusión.

4. Resultados

En este apartado se presentan los resultados obtenidos, mostrándose las curvas ROC de los experimentos con mejores detecciones de cada caso de detección, junto al AUC de la detección de cada método, además de la precisión de las detecciones de cambios de los métodos que han logrado mayores AUC en las curvas ROC. Por último, también se han representado cartográficamente dichas detecciones. En las figuras 15-18 se muestran las curvas ROC de las detecciones obtenidas con los ochos detectores empleados en cada caso de detección, siendo HACD el acrónimo de Hyperbolic ACD, y Chrono el diminutivo de Chronochrome. Únicamente se muestran los experimentos de cada caso en los que se logra mejorar las AUC obtenidas en la utilización de las imágenes originales. Es decir, solamente se han representado las curvas ROC de las detecciones aplicadas sobre los componentes principales (PC) cuyo número de PC ha mejorado la detección obtenida con las imágenes originales.

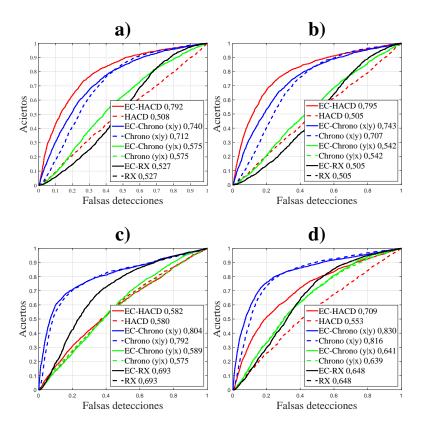


Figura 15: Curvas ROC y AUC obtenidas de las detecciones de los experimentos del caso de detección del incendio de Quesada y Huesa, siendo a) las detecciones de las imágenes sin corrección atmosférica, b) con corrección atmosferica, c) dos PC de las de corrección atmosférica y d) cuatro PC de las corregidas.

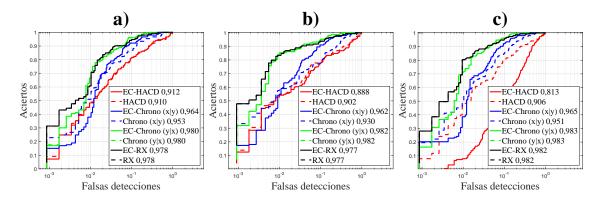


Figura 16: Curvas ROC en escala semilogarítmica y AUC obtenidas de las detecciones de los experimentos del caso de detección del desecado del lago Poopó, donde a) es la detección obtenida con las imágenes originales, b) la de cinco PC y c) la de seis PC.

Mediante el análisis del AUC de las curvas ROC, se observa cómo dependiendo del experimento concreto de cada caso, el método con mejores detecciones varía. No obstante, las mejores detecciones son las del desecado del lago (figura 16) y la de

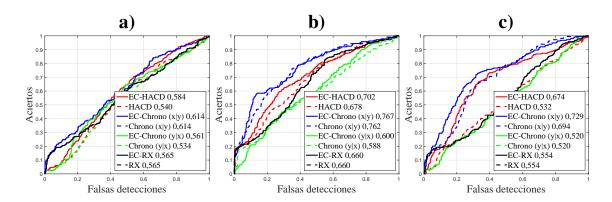


Figura 17: Curvas ROC y AUC obtenidas testeando de las detecciones de los experimentos del caso de detección de los cambios urbanos de Denver, donde a) es la detección obtenida con las imágenes originales, b) la de un PC y c) la de dos PC.

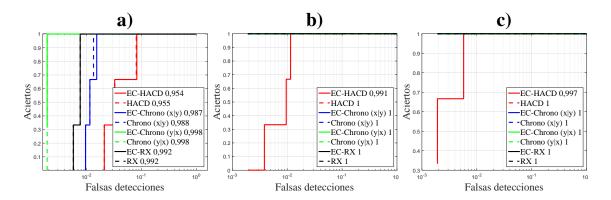


Figura 18: Curvas ROC en escala semilogarítmica y AUC de las detecciones de los experimentos del caso de detección de los cambios en los campos de fútbol, donde a) es la detección obtenida con las imágenes originales, b) la de dos PC y c) la de tres PC.

los cambios en los campos de fútbol (figura 18). Por contra, en el caso de Denver se obtienen las peores detecciones (figura 17). En las tablas 4-7 se muestra el coeficiente de Kappa y el porcentaje de exactitud global (EG), exactitud de la detección (ED) y exactitud de la no detección (END) de las detecciones realizadas con los métodos con mayores AUC, así como de las detecciones filtradas espacialmente.

Tabla 4: Evaluación de las detecciones de los cambios del incendio forestal.

		ISCA	ICCA	$2~\mathrm{PC}~\mathrm{ICCA}$	4 PC ICCA
	Método	EC-HACD	EC-HACD	EC-Chrono $(\mathbf{x} \mathbf{y})$	$\overline{\text{EC-Chrono}(\mathbf{x} \mathbf{y})}$
	AUC	0,792	0,795	0,804	0,830
	ν	$3,\!27$	2,59	2,31	2,05
	Kappa	0,35	0,39	0,49	0,48
Cin filtnen	EG (%)	$79,\!96$	80,57	83,76	83,33
Sin filtrar	ED (%)	$39,\!28$	43,79	51,04	52,96
	END (%)	92,00	$91,\!45$	93,43	92,32
Con filtrado	Kappa	0,38	0,44	0,54	0,55
	EG (%)	82,18	83,48	85,96	86,09
	ED (%)	$35,\!23$	41,49	50,70	$52,\!55$
	END (%)	96,12	$95,\!95$	96,43	96,05

Nota: ISCA = Imágenes sin corrección atmosférica, ICCA = Imágenes con corrección atmosférica.

Tabla 5: Evaluaciones de las detecciones del desecado del Lago Poopó.

		Imágenes Originales	5 PC	6 PC
	Método	Chrono $(\mathbf{y} \mathbf{x})$	Chrono $(\mathbf{y} \mathbf{x})$	Chrono $(\mathbf{y} \mathbf{x})$
	AUC	0,980	0,982	0,983
	ν	-	-	-
Sin filtrar	Kappa	0,81	0,85	0,83
	EG (%)	96,03	96,80	96,40
	ED (%)	85,21	88,60	84,30
	END (%)	97,46	97,85	98,00
Con filtrado	Kappa	0,86	0,90	0,87
	EG (%)	97,02	97,85	97,45
	ED (%)	86,39	90,28	86,30
	END (%)	98,44	98,86	98,93

La mejor precisión en el caso del incendio se ha logrado filtrando espacialmente la detección obtenida mediante el método EC-Chronochrome $(\mathbf{x}|\mathbf{y})$ aplicado sobre los cuatro PC de las imágenes originales, en el del lago filtrando la detección del

Tabla 6: Evaluaciones de las detecciones de los cambios urbanos de Denver.

		Imágenes Originales	1 PC	2 PC
	Método	Chrono $(\mathbf{x} \mathbf{y})$	EC-Chrono $(\mathbf{x} \mathbf{y})$	$\overline{\text{EC-Chrono}(\mathbf{x} \mathbf{y})}$
	AUC	0,614	0,767	0,729
	ν	-	2,31	2,07
	Kappa	0,10	$0,\!34$	0,09
Cin filtnen	EG (%)	74,70	$76,\!85$	74,61
Sin filtrar	ED (%)	8,48	40,00	6,90
	END (%)	98,81	90,00	$99,\!26$
Con filtrado	Kappa	0,10	0,39	0,09
	EG (%)	75,51	80,70	$75,\!36$
	ED (%)	7,15	35,80	$6,\!47$
	END (%)	99,80	96,65	99,84

Tabla 7: Evaluaciones de las detecciones de los cambios en los campos de fútbol.

		Imágenes Originales	2 PC	3 PC
	Método	Chrono $(\mathbf{y} \mathbf{x})$	Chrono $(\mathbf{y} \mathbf{x})$	$\overline{\text{Chrono } (\mathbf{y} \mathbf{x})}$
	AUC	0,998	1	1
	ν	-	-	-
Sin filtrar	Kappa	0,84	0,92	0,89
	EG (%)	99,71	99,86	99,81
	ED (%)	88,58	89,95	89,49
	END (%)	99,81	$99,\!95$	99,89
Con filtrado	Kappa	0,89	0,92	0,88
	EG (%)	99,82	99,87	99,78
	ED (%)	89,72	89,72	88,34
	END (%)	99,90	99,95	99,89

método Chronochrome $(\mathbf{y}|\mathbf{x})$ obtenida con cinco PC, en el de los cambio urbanos de Denver mediante el filtrado de la detección del método EC-Chronochrome $(\mathbf{x}|\mathbf{y})$ con un PC y finalmente en el de los cambios en los campos de fútbol mediante el método EC-Chronochrome $(\mathbf{y}|\mathbf{x})$ sobre dos PC sin filtrar. En todos los casos de detección se mejora la precisión de las detecciones al emplear los PC en lugar de las imágenes originales. También se mejora la precisión de las detecciones en todos los casos al aplicar el filtrado espacial, excepto en la detección de los cambios de los campos de fútbol, donde sin el filtrado las detecciones son muy precisas.

Finalmente en la figura 19 se representa cartográficamente las imágenes de las

detecciones que ha logrado una mayor precisión en las detecciones de los cambios ocurridos en cada caso de estudio. Además de dos composiciones RGB de la escena observada antes y después del cambio, y de las imágenes de verdad terreno. Todas las imagenes RGB son del color verdadero a excepción de las imágenes del incendio de Quesada y Huesa, en las que se ha empleado un falso color mediante la combinación de las bandas 7, 5 y 2 de Landsat-8 para resaltar la superficie quemada de la imagen.

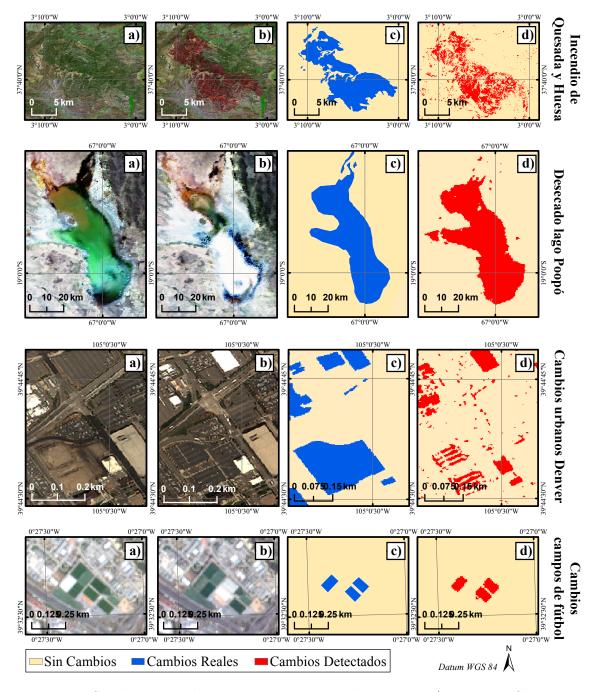


Figura 19: Cambios ocurridos en los cuatro casos de estudio: a) imagen RGB previa al cambio, b) imagen RGB posterior al cambio, c) imagen de verdad terreno de la zona con cambios, d) imagen de cambios detectada con mayor precisión.

Estas bandas se corresponden con el infrarrojo medio $(2,11-2,29 \ \mu m)$, infrarrojo cercano $(0,85-0,88 \ \mu m)$ y azul $(0,45-0,51 \ \mu m)$.

5. Discusión

En este trabajo se ha analizado la eficacia de las detecciones de cambios anómalos aplicando los métodos de la familia ACD y su versión EC en imágenes multiespectrales. Esto supone un avance en el estudio de dichos métodos dentro de las imágenes multiespectrales, dado que la gran mayoría de publicaciones al respecto se centran en imágenes hiperespectrales. El principal motivo de la gran utilización de estos métodos en imágenes hiperespectrales es que cuanto mayor es la componente espectral de las imágenes que se empleen para detectar los cambios, los detectores seleccionados ofrecen mejores resultados, ya que disponen de mayor información para ser capaces de detectar los cambios anómalos. Por ello han sido las detecciones de Denver con imágenes QuickBird, de únicamente cuatro bandas espectrales, en las que han registrado una precisión notablemente inferior que en los tres casos restantes, obteniendo en el mejor de los experimentos realizados un coeficiente de Kappa de 0,39 y una exactitud en las detecciones de los cambios ocurridos de un 35,79%, sin comprometer la tasa de falsas detecciones, ya que la exactitud de las no detecciones ha sido de un 96,65%.

Se ha demostrado que la componente espectral de las imágenes es muy importante para la detección de los cambios anómalos, dado que cuanta mayor información espectral haya, las matrices de covarianza en las que se basan los métodos empleados contendrán mayor información. Los mejores resultados acerca de la precisión de las detecciones obtenidas son los del caso de detección de los cambios ocurridos en los campos de fútbol, los cuales se han detectado con imágenes de Sentinel-2. Dicha precisión ha alcanzado un coeficiente de Kappa de 0,92 y una exactitud de la detección de un 89,72 % y de la no detección de un 99,95 %. Las imágenes de Sentinel-2 son las que tienen la componente espectral más amplia de todas las imágenes con las que se ha trabajado en esta investigación. Pero no siempre cuanto mayor sea el número de bandas de las imágenes, las detecciones serán más precisas, ya que dicha precisión

también depende mucho de cómo el cambio altera los valores de reflectividad de la energía solar que registran los sensores. Por este motivo, en las detecciones de los cambios provocados por el incendio en Quesada y Huesa, pese a utilizar imágenes Landsat-8 OLI, que tienen mayor resolución espectral que el producto MOD09A1 de MODIS, empleado en la detección del desecado del lago Poopó. Es en el segundo caso, donde se han logrado unas detecciones mucho más precisas, siendo el coeficiente de Kappa de dicha detección de un 0,90, la exactitud de la detección de un 90,28 % y de la no detección de un 98,86 %. Mientras que en la detección de los cambios ocasionados por el incendio, el coeficiente de Kappa es de 0,55, la exactitud de la detección de un 52,55 % y de la no detección de un 96,06 %. El principal motivo es que el desecado de un lago genera unas variaciones más notables en la energía solar reflejada en la superficie terrestre que el incendio de un área forestal dentro de los rangos espectrales de observación de dichos sensores.

En los resultados obtenidos se observa cómo dentro de la familia de detectores ACD y EC-ACD no existe un detector que siempre obtenga unos resultados mejores que el resto, lo que confirma lo dicho por Lu et al. (2004) y Hussain et al. (2013) acerca de que no existe un detector universal, sino que cada problema de detección de cambios precisa de un detector con unas características determinadas. Pero no solo eso, sino que cabe la posibilidad de que en un mismo problema de detección en el que en vez de utilizar las imágenes originales, éstas se sustituyan por componentes principales (PC), el método con el que se obtenían unos resultados mayores con las imágenes originales puede dejar de serlo. Esto es lo que ha ocurrido en todos los casos de detección realizados en este trabajo, a excepción de la detección del desecado del lago Poopó y de los cambios en los campos de fútbol mediante imágenes de MODIS y Sentinel-2, respectivamente, donde el método Chronochrome ($\mathbf{y}|\mathbf{x}$) ha obtenido en ambos casos las mejores detecciones en todos los experimentos mostrados. Esto es muy posible que tenga que ver con que en ambos casos los cambios anómalos tienen una distribución Gaussiana.

La versión EC de cada uno de los detectores de la familia ACD teóricamente debería mejorar o mantener el grado de acierto en la detección de cambios anómalos del mismo detector sin contornos elípticos, tal y como ya demostraron Theiler et

al. (2010) en imágenes hiperespectrales. Sin embargo esto no ocurre siempre ya que tal y como se ha visto en los resultados, hay casos en los que los métodos EC-ACD logran detecciones menos exactas que los ACD. Esta discrepancia sucede únicamente en los casos en los que los cambios anómalos existentes entre las imágenes presentan una distribución Gaussiana. En estos casos, para que la versión EC-ACD trabaje correctamente, el parámetro que regula el contorneado de las distribuciones de detección (ν) ha de tender a infinito. En las detecciones logradas con el método Hyperbolic ACD en los experimentos con cinco y seis PC del caso de detección del desecado del lago Poopó, y en todos los experimentos del caso de detección de cambios en los campos de fútbol, además del método Chronochrome ($\mathbf{x}|\mathbf{y}$) de este mismo caso, las AUC de las curvas ROC de los métodos EC-ACD son menores que las de los ACD. Por ello, en los casos en que las AUC y EC-ACD presentan el mismo valor, se ha decidido aplicar el método ACD, para así asegurar la Gaussianidad de la distribución de la detección, dado que no se puede otorgar un valor infinito al valor ν que regula el contorneado de las distribuciones.

Uno de los principales motivos de haber empleado los detectores ACD y EC-ACD es que estos detectores permiten aislar los cambios anómalos ocurridos en la superficie terrestre de los cambios regulares debidos al proceso de adquisición de las imágenes (Longbotham y Camps-Valls, 2014; Theiler et al., 2010). Este hecho se ha comprobado a través de las detecciones realizadas mediante las imágenes Sentinel-2, que no han sido corregidas atmosféricamente, y donde se ha obtenido la precisión en la detección más alta de todos los casos de detección realizados. No obstante, a fin de esclarecer hasta qué punto estos métodos son invariantes a los efectos de los cambios regulares ajenos a la superficie terrestre, se ha realizado un experimento específico con tal finalidad. Este ha sido analizar las detecciones de un mismo cambio con imágenes corregidas atmosféricamente y sin corregir. El cambio en cuestión ha sido el generado por el incendio forestal de Quesada y Huesa, y las imágenes han sido de Landsat-8. Así, la exactitud de la detección realizada mediante las imágenes corregidas ha sido mayor, siendo el coeficiente de Kappa, la exactitud global y la exactitud de la detección un 8,97 %, 0,75 % y 10,30 % mayores, respectivamente, que la de las imágenes sin corregir. Sin embargo, la exactitud de la no detección ha sido mayor a la obtenida con las imágenes sin corregir, aunque solamente un $0.59\,\%$

mayor. Esto posiblemente es debido al hecho de que al emplear las imágenes con corrección atmosférica, la exactitud en la detección de los cambios es notablemente mayor que al emplear las no corregidas, lo que genera que haya una probabilidad mayor de realizar falsas detecciones. De esta forma se verifica que los métodos empleados, a diferencia de otros, son capaces de funcionar a pesar de la existencia de cambios regulares no debidos a variaciones reales de la superficie observada. Aunque, las detecciones serán más precisas si se pueden emplear imágenes que hayan sido tratadas y corregidas de posibles fuentes de errores/alteraciones sistemáticas, como la dispersión atmosférica.

Respecto a la reducción de la componente espectral de las imágenes mediante PCA, se ha demostrado que al aplicar los métodos de detección de cambios utilizando los PC obtenidos en lugar de las imágenes originales, se obtienen unas detecciones con mayor precisión en todos los casos, aunque esta mejora no sucede utilizando cualquier número de componentes espectrales. El número óptimo de estos componentes depende de cada caso de detección, obteniéndose así las mejores precisiones en las detecciones con cuatro PC en el caso del incendio, cinco PC en el del lago, un PC en los cambios urbanos y dos PC en el de los campos de fútbol. En dichas detecciones se consigue obtener unas precisiones más elevadas que empleando las imágenes originales, siendo las mejoras más elevadas las del caso de los cambios urbanos de Denver, donde al utilizar la información extraída por el primer componente principal únicamente, se pasa de una exactitud en la detección bajísima, de solamente un 7.15% a un 35.79%, incrementándose así dicha exactitud en un 400.68%al emplear PCA. Y lo mismo ocurre con el coeficiente de Kappa, el cual pasa de 0,10 a 0,39. De esta forma se confirma lo dicho por Wu et al. (2015), acerca de que al aplicar PCA se mejoran las AUC de las curvas ROC en todos los casos de detección. Con la diferencia de que ellos aplican PCA a imágenes hiperespectrales, y en este trabajo se han empleado en multiespectrales. No obstante, en su investigación no comentan si el PCA también logra una detecciones con mayores precisiones al evaluar las imágenes de las detecciones en todos los casos de detección que realizan, ni tampoco que número óptimo de componentes principales emplean en cada caso, para lograr unas detecciones óptimas.

En algunos casos se ha visto cómo las curvas ROC otorgan una AUC mayor a algunos detectores, que más tarde, al examinar la precisión de las detecciones logradas por estos, no consiguen mejorar las logradas por los métodos que tenían una AUC menor. Esto se debe a que para aligerar el tiempo computacional de procesado de los datos, las curvas ROC se han calculado empleando una muestra de píxeles de test y entrenamiento, siendo los de test con los que se examina el acierto y las falsas alarmas de las detecciones, y los de entrenamiento, con los que se han modelado los detectores.

La finalidad de este procedimiento es poder comprobar la detección de cambios anómalos en píxeles donde el detector no ha trabajado, por lo que los píxeles de test y de entrenamiento siempre han se der diferentes. En esta investigación se ha empleado como píxeles de test el 2 % de los de las imágenes y de entrenamiento el 1 %. De ahí que en las curvas ROC de las detecciones realizadas con seis PC en el caso del desecado del lago, se consiga una AUC mayor que con la detección sobre cinco PC, pero que al evaluar la precisión de las imágenes de detección obtenidas, sea la de los cinco PC la que obtenga unos resultados mejores, dado que la curva ROC se ha calculado empleando una muestra, y la precisión sobre la totalidad de la imagen. Este desajuste entre la AUC mostrada por las curvas ROC y la evaluación de la precisión total de la detección ocurre también en el caso de las detecciones de los cambios urbanos de Denver y en el caso de las variaciones en los campos de fútbol. A pesar del mencionado problema, el cálculo de las curvas ROC mediante píxeles de test y entrenamiento es un buen sistema para identificar el método de detección más adecuado dentro de un tiempo de procesado operativo y funcional. Así, una posible solución a los problemas surgidos en este trabajo de desajuste entre el AUC y las evaluaciones de las imágenes de detecciones obtenidas sería ampliar el número de pixeles de test y entrenamiento, aunque esto supondría comprometer los tiempos de computación operativos que se han logrado en este trabajo.

Por último, el filtrado de moda espacial realizado a las imágenes de detección obtenidas mejora notablemente la precisión en la mayoría de casos, ya que suaviza las detecciones, pudiendo así eliminar píxeles sueltos derivados de una incorrecta detección. Únicamente no se mejora la precisión aplicando dicho filtrado en el caso

de los campos de fútbol, donde la detección sin filtrar obtiene un coeficiente de Kappa de un 0,92, y una exactitud global, de la detección y en la no detección de un de 99,86 %, 89,95 % y un 99,95 %, respectivamente. Valores muy difícilmente superables mediante la aplicación de un filtrado. En el resto de casos de detección la aplicación de este filtrado mejora de media un 9,53 % el coeficiente de Kappa, un 1,83 % la exactitud global, y un 2,17 % la de no detección. Sin embargo, reduce un 1.15 % de media la exactitud de la detección de los cambios. Así que la decisión final de emplear este filtrado depende de si al aplicarlo, pese a que se reduce ligeramente la exactitud de la detección, aumenta considerablemente la del resto de estadísticos que evalúan la precisión de la detección.

6. Conclusiones

En este trabajo se han logrado los objetivos propuestos, pudiendo así detectar de forma automática la mayoría de los cambios anómalos ocurridos en cuatro casos de estudio diferentes. Esta automatización de la detección supone un avance dentro de las ciencias de la Tierra, dado que permite una detección automática, rápida y eficaz de los cambios anómalos, reduciendo el tiempo de análisis y mejorando la rapidez de respuesta ante eventos anómalos, de catástrofes naturales, o antropogénicas.

Los métodos de detección de cambios anómalos empleados han sido los detectores de la familia ACD y la versión EC de dicha familia, y se han aplicado en imágenes multiespectrales de diferentes características espaciales y espectrales. De todos los detectores empleados no se ha podido identificar uno en concreto que siempre logre mejores resultados que el resto, ya que en cada caso de detección hay un método que ofrece resultados mejores. Aunque los métodos EC-ACD son los más adecuados en la mayoría de casos. No obstante, en los problemas en que los cambios anómalos son detectables mediante una distribución Gaussiana, que es cuando el área bajo la curva ROC del detector ACD es la misma que la del EC-ACD, es preferible emplear los detectores ACD. Esto se debe a que, para lograr que el contorneado elíptico sea Gaussiano, el parámetro que ajusta dicho contorneado ha de tender al infinito, lo cual no se puede aplicar en las detecciones realizadas.

Por otro lado, también se ha demostrado que los métodos de detección empleados trabajan mejor cuanto mayor es la componente espectral de las imágenes utilizadas, dado que en este trabajo las detecciones de cambios más bajas han sido las obtenidas con imágenes QuickBird de tan sólo cuatro bandas espectrales. No obstante, también se ha demostrado que no siempre que la resolución espectral de las imágenes sea mayor, las detecciones serán más precisas. Dado que lo fundamental para poder detectar los cambios ocurridos es que estos varíen la cantidad de energía solar que es reflejada, respecto a la que se reflejaba antes de ocurrir el cambio, y que dichas variaciones sean registradas por las bandas de las imágenes. Para lo que es esencial que las imágenes tengan bandas dentro de los rangos del espectro electromagnético en los que se ha alterado la cantidad de energía reflejada. Así, en el caso de la detección del desecado del lago Poopó, se ha logrado alcanzar una exactitud en la detección de los cambios mayor que en el caso de los cambios generados por el incendio forestal de Quesada y Huesa, a pesar de que las imágenes empleadas en la detección del desecado del lago tenían menos bandas espectrales.

Además se ha observado cómo los métodos de detección utilizados son resistentes a los cambios regulares debidos al proceso de adquisición de las imágenes, aunque no son invulnerables por completo, dado que se han logrado detecciones más exactas al emplear imágenes corregidas atmosféricamente que sin corregir de un mismo ejemplo de cambio anómalo. Esta elevada robustez ante cambios regulares ajenos a la escena por parte de los detectores empleados permite aplicar dichos métodos en la detección de zonas afectadas por catástrofes naturales, como tsunamis, terremotos o deslizamientos de tierra, en los que no hay tiempo suficiente para realizar ciertos pre-procesados a las imágenes, como por ejemplo la corrección atmosférica, puesto que reducir los tiempos de detección del área afectada es algo fundamental para poder salvar vidas.

Del mismo modo, en este trabajo también se ha demostrado como la reducción de la componente espectral de las imágenes mediante PCA funciona en todos los casos de detección vistos, aunque en cada caso se ha tenido que emplear un número de componentes principales diferente para poder mejorar la precisión de las detecciones logradas sin PCA. Asimismo, una vez obtenida la imagen de la detección de cambios

con mejores resultados, se ha comprobado cómo es posible afinar dicha detección en la mayoría de los casos aplicándole un filtrado espacial de moda.

Por último, los métodos vistos tienen en común que se basan en realizar detecciones lineales de los cambios anómalos ocurridos. Incluso la versión EC de los detectores de la familia ACD, la cual tan sólo ajusta los bordes de las distribuciones que detectan los píxeles con cambios del resto, pero sin salir de la linealidad de la detección. Así, en los casos que los píxeles con cambios no se pueden aislar de forma lineal del resto sin cometer falsas detecciones, los métodos propuestos no son los más adecuados. Es por ello que una futura línea de investigación es transformar los detectores empleados en este trabajo en métodos de detección no lineal. Esta transformación se puede realizar mediante la "kernelización" de los detectores empleados en este trabajo, siguiendo el trabajo de Longbotham y Camps-Valls (2014) o mediante técnicas de aprendizaje profundo como en Zhao et al. (2014).

7. Anexos

Anexo 1: Principales correcciones de las imágenes

Corrección geométrica

Las imágenes obtenidas mediante teledetección presentan distorsiones o anomalías geométricas que deben ser corregidas para evitar resultados erróneos a causa de un desplazamiento geométrico entre ambas imágenes. En la mayoría de problemas de detección de cambios en teledetección se busca lograr un registro entre ambas imágenes con un error de desplazamiento menor al tamaño de los píxeles de estas (Hussain et al., 2013). En la actualidad existen dos grandes familias de métodos de corrección geométrica de las imágenes, estos son las transformaciones basadas en modelos orbitales y las basadas en puntos de control. Los modelos orbitales permiten modelar aquellas fuentes de error geométrico conocido mediante la aplicación de transformaciones inversas a las realizadas por el sensor en el momento de la adquisición. Para ello, es preciso disponer con elevada precisión las características

orbitales del satélite, y especificaciones del sensor. Este tipo de métodos permite corregir errores geométricos ocasionados por la rotación y curvatura terrestre, y por la inclinación de la plataforma. Dichas correcciones son muy utilizadas en las imágenes de sensores con baja resolución espacial, o que trabajan en observación marítima, donde resulta muy complicado aplicar el método de los puntos de control (Mather, 1999, pág. 76-79).

Corrección radiométrica

La corrección radiométrica consiste en la conversión de los datos medidos por el sensor en cuentas digitales (CD) a una magnitud con significado físico, lo que permite homogeneizar los datos obtenidos con diferentes sensores o en momentos temporales distintos, lo cual es clave para la detección de cambios (Du et al., 2002). Dicha magnitud física es la radiancia (L), la cual es el total de energía radiada en una dirección determinada por unidad de área y ángulo sólido. Se mide en vatios por metro cuadrado y estereorradián (Wm - 2 sr - 1), y es un término fundamental en teledetección, ya que expresa la energía que mide el sensor (Chuvieco, 2008, pág. 49). La radiancia espectral (L_{λ}) es la radiancia de una única banda del espectro electromagnético. En esta investigación se ha trabajado únicamente con bandas del espectro óptico, por lo que la radiancia medida por el sensor en cada banda es consecuencia de la reflexión de la radiación solar en la Tierra, tanto en el suelo como en la atmosfera, ya que aún no se han corregido los efectos atmosféricos. Dicha medición es registrada en CD, y gracias a los coeficientes de calibración específicos de cada sensor, es posible obtener la L_{λ} a partir de las CD dada la siguiente expresión lineal (Chuvieco, 2008, pág. 272):

$$L_{sen,k} = a_{0,k} + a_{1,k} + CD_k (4)$$

donde $L_{sen,k}$ es la radiancia espectral en el techo de la atmosfera (TOA)⁷ medida por el sensor en la banda k, $a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración radiométrica del sensor para la banda k, y CD_k son la cuentas digitales en la banda k. A partir de $L_{sen,k}$ se puede calcular la reflectividad, siendo esta también en el techo de la

⁷Del inglés: Top of Atmosphere

atmosfera. La reflectividad se puede definir como la fracción del flujo de radiación incidente que es reflejado en la superficie (Sobrino, 2001, pág. 94), y se obtiene desde la $L_{sen,k}$ a través de la siguiente fórmula (Chuvieco, 2008, pág. 273):

$$\rho_k = \frac{D\pi L_{sen,k}}{E_{0,k}\cos\theta_i} \tag{5}$$

donde ρ_k es la reflectividad TOA de la banda k, $E_{0,k}$ es la irradiancia solar TOA en la banda k, D es el factor corrector de la distancia Tierra-Sol y θ_i es el ángulo cenital del flujo de radiación incidente. La capacidad para detectar y cuantificar los cambios en la superficie de la Tierra mediante teledetección depende en gran parte de la exactitud y precisión temporal de los datos que pueden proporcionar los sensores a través del tiempo. De ahí la necesidad de aplicar una correcta corrección radiométrica a los datos (Chander et al., 2009).

Corrección atmosférica

La atmosfera interactúa con la radiación electromagnética de diversas formas, ya sea absorbiendo, dispersando o emitiendo radiación (Pinilla, 1995, pág. 25). En el rango espectral óptico únicamente se producen los dos primeros procesos, ya que la emisión atmosférica únicamente se da en el espectro térmico. La absorción atmosférica es producida por los gases que componen la atmosfera a unas determinadas longitudes de onda, las longitudes en las que no existe absorción atmosférica se les conocen como ventanas atmosféricas, y son los rangos espectrales en los que se trabaja en teledetección. Dado que la composición gaseosa de la atmosfera es constante y uniforme, y que se trabaja en los rangos en los que no hay absorción atmosférica, los posibles cambios atmosféricos que afecten a la adquisición de imágenes en el espectro óptico dependen únicamente de la dispersión. La dispersión es producida por el choque entre la energía electromagnética y partículas atmosféricas, principalmente aerosoles y gotas de agua. Los aerosoles son partículas en suspensión cuyo origen puede ser oceánico, como las sales, o continental como el polvo o las cenizas (King et al., 1999). Dado que la concentración de los aerosoles como de las gotas de agua es muy variante en la atmosfera en el espacio y tiempo, es sumamente complicado cuantificar su influencia en la energía que capta el sensor durante la adquisición de la imagen. Asimismo, dicha influencia no afecta igual a la energía descendente que a la ascendente, dado que atraviesan un espesor de atmosfera diferente. Para estimar la energía reflejada únicamente en la superficie terrestre sin tener en cuenta los efectos de la atmosfera se emplea la siguiente expresión (Gilabert et al., 1994):

$$L_{sen,k} = L_{su,k}\tau_{k,0} + L_{a,k} \tag{6}$$

donde $L_{su,k}$ es la radiancia de la banda k reflejada en la superficie, $\tau_{k,0}$ es la transmisividad del flujo ascendente en la banda k y $L_{a,k}$ la radiancia de la banda k que es reflejada hacia el sensor. Actualmente se suelen emplear códigos de transferencia radiativa para simular las mencionadas magnitudes y así poder despejar el valor de la energía reflejada únicamente en la superficie. Algunos de los códigos radiativos más empleados en la actualidad son MODTRAN (Moderate spectral resolution atmospheric Transmittance), RTTOV (Radiative Transfer for TIROS Operational Vertical Sounder), 6S (Simulation of the Satellite Signal in the Solar Spectrum) y ATCOR (Atmospheric and Topographic Correction) (Pflug et al., 2015; Sendra et al., 2015).

Anexo II: Webs de los sensores de las imágenes empleadas

- Landsat-8: http://landsat.usgs.gov/landsat8.php
- MODIS: http://modis.gsfc.nasa.gov/
- QuickBird: http://www.satimagingcorp.com/satellite-sensors/quickbird/
- Sentinel-2: https://sentinel.esa.int/web/sentinel/sentinel-data-access

8. Bibliografía

- Aguirre-Gutiérrez, J., Seijmonsbergen, A. C., y Duivenvoorden, J. F. (2012). Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. *Applied Geography*, 34:29–37.
- Aplin, P. (2004). Remote sensing: land cover. *Progress in Physical Geography*, 28(2):283–293.
- Bouziani, M., Goïta, K., y He, D. C. (2010). Automatic change detection of buildings in urban environment from very high spatial resolution images using existing geodatabase and prior knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1):143–153.
- Bruzzone, L. y Prieto, D. F. (2000). Automatic analysis of the difference image for unsupervised change detection. *Geoscience and Remote Sensing, IEEE Transactions on*, 38(3):1171–1182.
- Camps-Valls, G., Gómez-Chova, L., Calpe-Maravilla, J., Martín-Guerrero, J. D., Soria-Olivas, E., Alonso-Chordá, L., y Moreno, J. (2004). Robust support vector method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on Geoscience and Remote sensing*, 42(7):1530–1542.
- Camps-Valls, G., Tuia, D., Gómez-Chova, L., Jiménez, S., y Malo, J., editores (2011).

 Remote Sensing Image Processing. Morgan & Claypool Publishers, LaPorte, CO, USA.
- Chan, J. C.-W., Chan, K.-P., y Yeh, A. G.-O. (2001). Detecting the nature of change in an urban environment: A comparison of machine learning algorithms. *Photogrammetric Engineering and Remote Sensing*, 67(2):213–226.
- Chander, G., Markham, B. L., y Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. Remote Sensing of Environment, 113(5):893–903.

- Chen, G., Hay, G. J., Carvalho, L. M., y Wulder, M. A. (2012). Object-based change detection. *International Journal of Remote Sensing*, 33(14):4434–4457.
- Chuvieco, E. (2008). Teledetección ambiental: la observación de la Tierra desde el espacio. Barcelona: Ariel.
- Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., y Lambin, E. (2004). Review articledigital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25(9):1565–1596.
- Dai, X. y Khorram, S. (1999). Remotely sensed change detection based on artificial neural networks. *Photogrammetric Engineering and Remote Sensing*, 65:1187– 1194.
- Du, Y., Teillet, P. M., y Cihlar, J. (2002). Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. *Remote Sensing of Environment*, 82(1):123–134.
- Fisher, P. (1997). The pixel: a snare and a delusion. *International Journal of Remote Sensing*, 18(3):679–685.
- Gilabert, M., Conese, C., y Maselli, F. (1994). An atmospheric correction method for the automatic retrieval of surface reflectances from TM images. *International Journal of Remote Sensing*, 15(10):2065–2086.
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., Pretty, J., Robinson, S., Thomas, S. M., y Toulmin, C. (2010). Food security: the challenge of feeding 9 billion people. *Science*, 327(5967):812–818.
- Hay, G. J. y Castilla, G. (2008). Geographic object-based image analysis (GEOBIA): A new name for a new discipline. En *Object-based image analysis*, pp. 75–89. Springer.
- Hussain, M., Chen, D., Cheng, A., Wei, H., y Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. ISPRS Journal of Photogrammetry and Remote Sensing, 80:91–106.

- Im, J. y Jensen, J. R. (2005). A change detection model based on neighborhood correlation image analysis and decision tree classification. Remote Sensing of Environment, 99(3):326–340.
- King, M. D., Kaufman, Y. J., Tanré, D., y Nakajima, T. (1999). Remote sensing of tropospheric aerosols from space: Past, present, and future. Bulletin of the American Meteorological Society, 80(11):2229–2259.
- Lambin, E. F. y Strahler, A. H. (1994). Indicators of land-cover change for change-vector analysis in multitemporal space at coarse spatial scales. *International Journal of Remote Sensing*, 15(10):2099–2119.
- Listner, C. y Niemeyer, I. (2011). Object-based change detection. *Photogrammetrie-Fernerkundung-Geoinformation*, 2011(4):233–245.
- Liu, C., Frazier, P., y Kumar, L. (2007). Comparative assessment of the measures of thematic classification accuracy. *Remote Sensing of Environment*, 107(4):606–616.
- Lizarazo, I. y Barros, J. (2010). Fuzzy image segmentation for urban land-cover classification. *Photogrammetric Engineering & Remote Sensing*, 76(2):151–162.
- Longbotham, N. y Camps-Valls, G. (2014). A family of kernel anomaly change detectors. Lausanne, Switzerland. IEEE Workshop on Hyperspectral Image and Signal Processing, Whispers.
- Lu, D., Mausel, P., Brondizio, E., y Moran, E. (2004). Change detection techniques.

 International Journal of Remote Sensing, 25(12):2365–2401.
- Ma, L., Crawford, M. M., y Tian, J. (2010). Anomaly detection for hyperspectral images based on robust locally linear embedding. *Journal of Infrared, Millimeter, and Terahertz Waves*, 31(6):753–762.
- Mas, J. F. (1999). Monitoring land-cover changes: a comparison of change detection techniques. *International Journal of Remote Sensing*, 20(1):139–152.
- Mather, P. M. (1999). Computer Processing of Remote-Sensed Images. John Wiley.
- Nielsen, A. A., Conradsen, K., y Simpson, J. J. (1998). Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data:

- New approaches to change detection studies. Remote Sensing of Environment, 64(1):1–19.
- Niemeyer, I., Marpu, P. R., y Nussbaum, S. (2008). Change detection using object features. En *Object-Based Image Analysis*, pp. 185–201. Springer.
- Niu, Y. y Wang, B. (2016). Hyperspectral anomaly detection based on low-rank representation and learned dictionary. *Remote Sensing*, 8(4):289.
- Olofsson, P., Foody, G. M., Stehman, S. V., y Woodcock, C. E. (2013). Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, 129:122–131.
- Pflug, B., Main-Knorn, M., Makarau, A., y Richter, R. (2015). Validation of aerosol estimation in atmospheric correction algorithm ATCOR. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 40(7):677.
- Pinilla, C. (1995). Elementos de teledetección. Madrid: RA-MA Editorial.
- Radke, R. J., Andra, S., Al-Kofahi, O., y Roysam, B. (2005). Image change detection algorithms: a systematic survey. *Image Processing, IEEE Transactions on*, 14(3):294–307.
- Reed, I. S. y Yu, X. (1990). Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 38(10):1760–1770.
- Rogan, J., Franklin, J., y Roberts, D. A. (2002). A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. *Remote Sensing of Environment*, 80(1):143–156.
- Sendra, V., Camacho, F., Sánchez, J., Jiménez-Muñoz, J., y García-Haro, F. J. (2015). Método para la corrección atmosférica de imágenes Landsat. XVI Congreso de la AET.

- Singh, A. (1989). Review article digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing*, 10(6):989–1003.
- Sobrino, J. A. (2001). *Teledetección*. Valencia: Servicio de publicaciones de la Universitat de València.
- Strahler, A. N. y Strahler, A. H. (1989). *Geografía física*. Barcelona: Ediciones Omega SA.
- Tewkesbury, A. P., Comber, A. J., Tate, N. J., Lamb, A., y Fisher, P. F. (2015). A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment*, 160:1–14.
- Theiler, J. y Perkins, S. (2006). Proposed framework for anomalous change detection. En *ICML Workshop on Machine Learning Algorithms for Surveillance and Event Detection*, pp. 7–14.
- Theiler, J., Scovel, C., Wohlberg, B., y Foy, B. R. (2010). Elliptically contoured distributions for anomalous change detection in hyperspectral imagery. *Geoscience and Remote Sensing Letters*, *IEEE*, 7(2):271–275.
- Versluis, A. y Rogan, J. (2010). Mapping land-cover change in a Haitian watershed using a combined spectral mixture analysis and classification tree procedure. Geocarto International, 25(2):85–103.
- Vila, J. P. S. y Barbosa, P. (2010). Post-fire vegetation regrowth detection in the Deiva Marina region (Liguria-Italy) using Landsat TM and ETM+ data. *Ecolo-gical Modelling*, 221(1):75–84.
- Warner, T. (2011). Kernel-based texture in remote sensing image classification. Geography Compass, 5(10):781–798.
- Wu, C., Zhang, L., y Du, B. (2015). Hyperspectral anomaly change detection with slow feature analysis. *Neurocomputing*, 151:175–187.
- Zare-Baghbidi, M., Homayouni, S., y Jamshidi, K. (2015). Improving the RX anomaly detection algorithm for hyperspectral images using FFT. *Modeling and Simulation in Electrical and Electronics Engineering*, 1(2):33–39.

Zhao, J., Gong, M., Liu, J., y Jiao, L. (2014). Deep learning to classify difference image for image change detection. En 2014 International Joint Conference on Neural Networks (IJCNN), pp. 411–417.