

# Efficient Dimensionality Reduction Using Principal Component Analysis for Image Change Detection

M. Martínez-Izquierdo, I. Molina-Sánchez, and M. Morillo-Balsera

**Abstract**— Change detection in image processing is the process of identifying differences by comparing images taken at different times. There are several digital change detection techniques; nevertheless, there is no universally optimal change detection methodology: the choice is dependent upon the application. Change detection methods based on multispectral space transformations like Principal Component Analysis (PCA) show good solutions for remote sensing applications. One advantage of PCA is in reducing data redundancy between bands and emphasizing different information in derived components. This work focus on the PCA exploitation for the SPOT multispectral image change detection. Thresholds are applied to the transformed image (PC2) to isolate the pixels that have changed. Thresholding methods require a decision as to where to place threshold boundaries in order to separate areas of change from those of no change. The accuracy of change detection maps that are derived with SPOT data is represented in terms of producer's accuracy, user's accuracy, and overall accuracy, which are calculated from an error matrix (or confusion matrix). The obtained results have demonstrated solving efficiently the change detection problem.

**Index Terms**—Binary maps, Change detection, Image analysis, Principal Component Analysis (PCA), Remote Sensing, SPOT images.

## I. INTRODUCCIÓN

UN proceso de Detección de Cambios (DC) se define como aquel que permite identificar diferencias en el estado de un objeto o fenómeno, mediante su observación en diferentes intervalos temporales [1]. Las imágenes de Teledetección, registradas mediante sensores transportados en plataformas aeroespaciales, se consideran una buena fuente de datos, que permite disponer de una excelente información sobre los cambios producidos en la ocupación del suelo, tanto en las zonas urbanas como no urbanas. Algunas de las aplicaciones de esta información son, por ejemplo: la gestión

en la toma de decisiones en la vigilancia de los ecosistemas y la planificación urbana.

El análisis de una trayectoria temporal de cambios en un área geográfica dada, puede basarse en el análisis de dos escenas de ese área, registradas en dos fechas diferentes (bi-temporales) o de manera general, en una serie multitemporal. En cualquiera de sus variantes, es un tema de investigación de gran interés en el ámbito del procesado e interpretación de imágenes digitales multiespectrales [2]. Su verdadera utilidad radica en la capacidad de discriminar cambios significativos, tipificados como tales, dependiendo de la aplicación prevista para los resultados obtenidos.

Hay diferentes métodos disponibles que han sido formalizados en la literatura científica en excelentes compendios [3] [4] [5] [6], que pueden facilitar la elección de la metodología de detección de píxeles o zonas de cambio y no cambio, en un estudio multitemporal. Sin embargo, la mayoría de los autores coinciden en que no existe una metodología de detección de cambios universalmente óptima [7].

Un algoritmo básico para detectar cambios, parte de una secuencia temporal de imágenes  $\{I_1, I_2, \dots, I_M\}$ , típicamente  $M=2$  como imágenes de entrada, y genera como salida, una imagen binaria  $B: R^2 \rightarrow [0,1]$ , denominada mapa de cambios, que identifica las regiones cambiantes teniendo en cuenta (1)

$$B(x) = \begin{cases} 1, & \text{si hay un cambio significativo en } x \text{ de } I_M \\ 0, & \text{en los demás casos.} \end{cases} \quad (1)$$

Básicamente, de manera general, los algoritmos de detección de cambios se agrupan según dos enfoques: post-clasificación y pre-clasificación. En el primer grupo, se incluyen métodos supervisados que requieren información de referencia del terreno, para básicamente, clasificar y obtener mapas temáticos de transiciones entre clases de coberturas terrestres que cambian. En estos, la precisión en la determinación de cambios se ve influida por los errores que pueden surgir en el proceso de clasificación.

En cambio, los métodos pre-clasificación, generalmente basados en la detección de las diferencias radiométricas existentes entre las imágenes, se muestran más atractivos, porque no necesitan datos de referencia, conocimiento previo o supervisión del área geográfica de estudio. Sin embargo, en estos métodos, se hace patente un problema fundamental,

M. E. Martínez-Izquierdo, Departamento de Arquitectura y Tecnología de Sistemas Informáticos, E.T.S.I. Informáticos. Universidad Politécnica de Madrid, España (e-mail: emartinez@fi.upm.es).

I. Molina-Sánchez, Departamento de Ingeniería Topográfica y Cartografía, E.T.S.I. Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, España (e-mail: inigo.molina@upm.es).

M. C. Morillo-Balsera, Departamento de Ingeniería Topográfica y Cartografía, E.T.S.I. Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, España (e-mail: cmorillo@topografia.upm.es).

como es el hecho de que cambios significativos, objetivo del análisis y de la aplicación final, están inevitablemente influidos por otros que no lo son, y pueden influir en gran medida en la precisión del método utilizado. Entre las fuentes de posibles errores radiométricos, se pueden mencionar: el ruido sensor/imagen, los cambios en condiciones atmosféricas e iluminación y los errores de registro entre las imágenes multi-temporales [8]. Por lo tanto, en el caso de los métodos preclasificación, un control radiométrico de las imágenes se hace imprescindible.

En Teledetección, los sensores multi-espectrales e hiper-espectrales registran información sobre de características biofísicas de coberturas del terreno en varios canales o bandas [2]. Si el procesamiento de esta información requiere de un tratamiento estadístico, aparecen ciertos inconvenientes que son inherentes a la propia imagen multibanda, como son: la redundancia de información entre bandas, el solapamiento de las respuestas espectrales mixtas de los diferentes objetivos situados en el terreno y la complejidad computacional del tratamiento de estos datos.

En el caso de la existencia de información redundante entre imágenes digitales [9] [10] en general, y en particular en imágenes multibanda registradas mediante sensores de Teledetección [11] [12], la transformación a Componentes Principales (CP) se presenta como una buena solución para minimizar este hecho. Aunque en el caso de imágenes multibanda, este análisis genera el mismo número de componentes que las variables de entrada (bandas), una característica clave del método es la concentración de la varianza (mayor porcentaje de información) de los datos originales, en los primeros CP, lo que permite optimizar el coste computacional de cualquier metodología planteada, reduciendo el procesamiento de la información, trabajando únicamente con estas bandas que presentan mayor porcentaje de varianza. Es decir, es posible seleccionar una dimensionalidad menor que la de la imagen original, sin pérdida de información relevante.

El análisis mediante Componentes Principales (ACP) es una estrategia clásicamente utilizada en el procesamiento de datos multidimensionales [13] [14]. Esta técnica estadística de compresión sin pérdida de información, tiene como objetivo reducir la variancia y dimensionalidad del conjunto de datos, por proyección de los datos transformados a lo largo de unos nuevos ejes (subespacio) o componentes no correlacionados. Dentro de los métodos matemáticos existentes para establecer los nuevos ejes o CP, se encuentra aquel que consiste en encontrar la proyección que maximiza la varianza [15]. Se trata de una transformación lineal ortogonal que presenta la mayor variancia de datos en un primer eje, denominado Primer Componente Principal (CP1), disminuyendo en un segundo eje (ortogonal al primero), denominado Segundo Componente Principal (CP2) y así la variancia irá decreciendo en los sucesivos componentes.

La aplicación del ACP en el contexto de la detección de cambios en imágenes, ha sido muy utilizada en diferentes ámbitos y para diferentes tipos de imagen. En segmentación de imágenes de video [16], el ACP permite realizar una extracción de características de los datos de entrada, que

optimiza el resultado del proceso de segmentación.

Básicamente en imágenes de Teledetección, se pueden seguir dos posibles estrategias de aplicación: transformación por separado o transformación conjunta [17]. En el primer caso se aplica a las imágenes de diferentes fechas de adquisición por separado, y en el segundo caso se mezclan las imágenes.

En [18], se realiza una división previa de la imagen en imágenes más pequeñas o bloques, con objeto de realizar un ACP multi-bloque. Finalmente, se analizan en conjunto las bandas transformadas en la serie multitemporal, con el resultado de un aumento de la complejidad y coste computacional del proceso. Sin embargo, Munyati [19] utiliza la transformación de datos mezclados, para posteriormente realizar un estudio comparativo entre las composiciones color (RGB, Red-Green-Blue) de los tres primeros CP y de las imágenes ópticas (LANDSAT) originales de las diferentes fechas. En [19], no se especifican precisiones en los resultados por lo que no es posible evaluarlos adecuadamente.

En [20] se trabaja con imágenes reescaladas multitemporales procedentes de dos sensores diferentes como ETM+ (LANDSAT) y SPOT-5, se utiliza la estrategia de transformación conjunta para la reducir la dimensionalidad y a continuación, se realiza una clasificación temática híbrida no supervisada/supervisada (ISODATA + Maximum Likelihood). Su objetivo es obtener un mapa temático etiquetado en base a clases que cambian [20].

En esta misma línea de trabajo, comentada en la referencia anterior, se encuentra [21] donde se propone utilizar un kernel-ACP en el caso de que la estructura de datos no pudiera representarse en un subespacio lineal. La metodología de clasificación utilizada en este caso, está basada en el concepto de *ensamble* de clasificadores individuales, construidos a partir de la selección de conjuntos aleatorios de datos. Los errores en los resultados de los clasificadores individuales se eliminan por votación mayoritaria. Los estudios de precisión de los resultados de clasificación no son mostrados en el estudio referenciado.

En el caso de imágenes SAR (Synthetic Aperture Radar) multitemporales, para analizar cambios en áreas urbanas, en [22] se utiliza como detector, el algoritmo de reducción de ruido NLM (Non Local Means) unido al ACP, obteniéndose buenos resultados.

A diferencia de los trabajos mencionados, el planteamiento de este trabajo se basa en la utilización única de la imagen CP2, para generar el mapa binario de cambios de una zona de estudio dada, mostrando tanto regiones de píxeles de cambio, como píxeles de no cambio, conjuntamente. Se realiza una propuesta metodológica pre-clasificación de detección de cambios en imágenes SPOT bi-temporales, mediante ACP basado en el análisis de la variancia, aplicando una estrategia de transformación conjunta. En un análisis de los valores de las correlaciones entre los componentes transformados y las bandas originales, se demuestra que el CP2 es el que presenta mayor diferencia entre las imágenes de las dos fechas, por lo que la utilización únicamente de este componente transformado en el estudio realizado, reduce eficazmente el coste computacional de procesamiento de imagen. Para obtener el mapa de cambios

final, se realizan diversos experimentos con diferentes algoritmos de umbralización automática de la imagen CP2. Un análisis de errores y precisiones sobre dichos mapas, muestran la eficiencia de la selección de la banda transformada CP2 para realizar el estudio de detección de cambios.

Tanto la transformación a Componentes Principales, como la umbralización, son procesos automáticos implementados clásicamente, en software de procesamiento de imagen multi-banda registrada mediante Teledetección, lo que facilita en gran medida el proceso de detección de cambios.

La organización del trabajo es la siguiente: en la Sección II, se resume algebraicamente el Análisis de Componentes Principales (ACP); en la sección III, se describen los casos de estudio; en la sección IV, se describe la metodología propuesta; en la sección V, se muestra un análisis de los resultados obtenidos; y finalmente, se pueden encontrar las conclusiones en la sección VI.

## II. ANÁLISIS DE COMPONENTES PRINCIPALES

Se trata de una transformación de datos multivariados a un nuevo conjunto de componentes, que persigue reducir la redundancia existente en el conjunto inicial. Los nuevos componentes se sitúan en un nuevo subespacio, originado a partir del espacio multivariado original. En términos de álgebra lineal, se describe a continuación el ACP aplicado a este trabajo.

Se parte de una matriz de datos  $X$  de  $n$  observaciones de  $k$  variables (imagen multi-espectral de  $n$  píxeles y  $k$  bandas espectrales), cuyo elemento genérico de dicha matriz es  $x_{ij}$  (nivel de gris del píxel  $i$  en la banda  $j$ ). La covarianza está representada por la matriz de dimensiones  $K \times K$ ,  $C_x = [c_{jk}]$  cuyas entradas son indicadas de acuerdo a (2):

$$c_{ij} = \frac{1}{N} \sum_{i=1}^N (x_{ij} - \mu_j)(x_{ik} - \mu_k) \quad (2)$$

donde  $x_{ij}$  es la  $i$ -ésima observación de la  $j$ -ésima variable.  $\mu_j$  y  $\mu_k$  son la media de  $j$ -ésima y  $k$ -ésima variables, respectivamente.

Dadas las variables iniciales ( $x_1, \dots, x_j, \dots, x_k$ ), las nuevas variables o Componentes Principales (CP) se obtienen combinando linealmente las originales, de forma que satisfagan como condiciones una maximización de la varianza y que sean ortogonales entre sí (condición para que no estén correlacionadas). Llamando  $y_f$  a las nuevas variables ( $f=1, \dots, k$ ), la transformación CP puede ser definida como  $\mathbf{Y}=\mathbf{X}\mathbf{U}$  donde  $\mathbf{U}$  es la matriz  $K \times K$  resultante de la transformación, cuyas columnas son los vectores propios de  $C_x$ .  $\mathbf{X}$  es la  $N \times K$  matriz de datos, cuyas columnas y filas representan las variables y observaciones respectivamente. Las columnas de  $\mathbf{Y}$  son los CP. La correlación entre las variables y los CP se denominan valores propios y están relacionados con las varianzas de los ejes transformados.

## III. CASOS DE ESTUDIO

Se han seleccionado tres escenas bi-temporales (Fig. 1) del

satélite SPOT-5 registradas el 24 Julio de 2005 y el 7 Septiembre de 2007, situadas en la Comunidad de Madrid (España). El satélite SPOT proporciona imágenes con una banda pancromática, PAN, de resolución espacial de 2.5 (o 5) metros; tres bandas, G, R y NIR, con resolución espacial de 10 metros y una banda, IRM, con una resolución espacial de 20 metros (Tabla I). El rango dinámico de los datos es de 8 bits. En este estudio se utilizan las bandas G, R y NIR.

TABLA I  
CARACTERÍSTICAS DE LAS IMÁGENES SPOT

Escenas SPOT-XS	Dimensiones (píxeles)	Coordenadas geográficas del centro (UTM) <sup>a</sup>
1	699x678	441280.0800E, 4492204.9700N
2	723x723	442151.6644E, 4516907.7217N
3	699x699	426070.1300E, 4511774.7900N
Bandas: Intervalos de longitudes de onda, zona del espectro		G (500–590 nm), Verde (Visible) R (610–680 nm), Rojo (Visible) NIR (780–890 nm), Infrarrojo próximo MIR (1580–1750 nm), Infrarrojo medio

<sup>a</sup> Universal Transverse Mercator

La Fig. 1 muestra una composición falso color (RGB = NIR, R, G) de las imágenes multispectrales SPOT (SPOT-XS).




Fig. 1. Imágenes SPOT originales (SPOT-5. Plan Nacional de Teledetección de España (PNT). Instituto Geográfico Nacional @CNES. Fechas de registro: 24 Julio de 2005 y 7 de Septiembre de 2007, Spot Image S.A). Composición RGB falso color NIR-R-G. Véanse algunos detalles destacados (zonas delineadas en color amarillo).

Mediante una inspección visual de las diferentes escenas mostradas en dicha figura, se pueden destacar los siguientes cambios observados:

- En la Escena 1, se han producido principalmente cambios derivados del crecimiento urbano de la zona geográfica, con aparición de nuevos edificios y explanación del terreno para la construcción de nuevas urbanizaciones.
- En la Escena 2, principalmente, se producen cambios debidos a la disminución drástica del volumen hídrico del reservorio acuoso (embalse de Pedrezuela) que ocupa principalmente la mayor superficie de agua en la imagen.

- En la Escena 3, destacan los cambios que se producen debido al aumento del volumen hídrico del reservorio acuoso (embalse de Santillana), destacando la desaparición de las zonas arenosas central y aledañas al borde.

Además de los cambios destacados, aparecen los de tipo estacional, debidos básicamente a la modificación de la cobertura vegetal (en color rojo en este tipo de composición color) existente en todas las escenas.

#### IV. METODOLOGÍA

##### A. Preprocesamiento. Control radiométrico

Para que cualquier análisis de imágenes multi-temporales sea eficaz, debe ser garantizado un co-registro preciso. Además hay que tener en cuenta que las condiciones atmosféricas pudieran ser diferentes durante el proceso de adquisición de las imágenes en las diferentes fechas. Para su comparación en el estudio previsto, las imágenes deben ser normalizadas. Para ello, se han revisado una gran variedad de técnicas de normalización radiométrica relativa [23] y aunque los datos SPOT se suministran con corrección radiométrica, se requiere normalizar las imágenes para trabajar con valores de radiancia o reflectancia. Para ello, se utiliza la información de los ficheros de metadatos que acompañan a las imágenes suministradas. En este trabajo, se prefiere aplicar una normalización radiométrica relativa a las imágenes correspondientes al año 2005, con respecto a las imágenes de 2007, de acuerdo a lo especificado en [24].

##### B. Imagen Índice de Cambios a partir de ACP

Para calcular la imagen Índice de Cambios, en primer lugar, se genera un archivo de datos mezclados de las dos fechas. Este fichero está formado por las seis bandas (B1,..., B6), correspondientes a las imágenes bi-temporales de cada escena objeto de estudio. Las bandas B1, B2 y B3 corresponden a las bandas G, R y NIR del año 2005, y las bandas B4, B5 y B6 a las correspondientes del año 2007.

Para llevar a cabo el análisis de los datos de las imágenes mediante CP, se plantean las siguientes etapas [25]:

###### 1) Cálculo de la matriz de varianza-covarianza ( $C_x$ ) de los datos

La matriz de varianza-covarianza se construye teniendo en cuenta, que los elementos de la diagonal principal corresponden a los resultados obtenidos, al calcular las varianzas de los niveles digitales (ND) de los píxeles de cada banda. Los elementos fuera de la diagonal, son las covarianzas calculadas entre los ND de dos en dos bandas. Esta matriz es cuadrada.

El objetivo del ACP es generar un nuevo sistema de coordenadas en el espacio multispectral, en el cual los datos pueden ser representados sin correlación, de tal manera, que la matriz de varianza-covarianza sea diagonal en el nuevo sistema de coordenadas.

###### 2) Cálculo de los valores y vectores propios a partir de la matriz $C_x$ , para obtener el nuevo espacio de componentes

Los valores propios ( $\lambda$ ) se definen como las raíces de la ecuación correspondiente al polinomio característico (3) de la matriz  $C_x$ .

$$\text{determinante}(Cx - \lambda I) = |Cx - \lambda I| = 0 \quad (3)$$

donde  $I$  es la matriz identidad.

Asociado a cada valor propio, está el vector propio, un conjunto de coordenadas que definen la dirección del eje principal asociado. Por lo tanto, las magnitudes de los valores propios describen la longitud y los vectores propios describen la dirección de los ejes principales.

El porcentaje total de varianza para cada nuevo componente  $y_f$  se calcula mediante (4):

$$\%var = 100 \times \frac{\lambda_{y_f}}{\sum_{y=1}^k \lambda_y} \quad (4)$$

Donde  $\lambda_y$  son los valores propios de cada componente.

Para un análisis completo de los resultados obtenidos, se calculan los coeficientes de carga o correlación ( $R$ ) entre cada CP y la banda  $k$  original a partir de (5):

$$R_{y,k} = u_{y,k} (\lambda_y)^{1/2} \quad (5)$$

donde  $u_{y,k}$  son los elementos de los vectores propios.

###### 3) Transformación lineal de los datos de imagen utilizando los coeficientes de la matriz de los vectores propios

Por ejemplo, en un conjunto de  $k$  bandas, el valor del píxel en el punto  $(i, j)$  el segundo CP (CP2) se calcula según (6):

$$cp2_{ij} = a_1 x_{ij1} + a_2 x_{ij2} + \dots + a_k x_{ijk} \quad (6)$$

donde  $cp2_{ij}$  es el valor del píxel de la fila  $i$ , columna  $j$  en la imagen correspondiente al CP2, los valores  $a_1, a_2, \dots, a_k$  son los elementos del segundo vector propio para las diferentes bandas, y  $x_{ijk}$  es el valor del píxel en posición  $(i, j)$  localizado en las diferentes bandas. Así, la imagen CP se genera como la suma de los productos de los vectores propios, con los correspondientes valores digitales de la imagen inicial.

##### C. Obtención y Evaluación del Mapa de Cambios

A partir de la imagen del segundo Componente Principal (CP2) se obtiene una imagen binaria mediante un proceso de umbralización [26] [27] [28]. La imagen binaria donde los cambios están representados por "1" y los no cambios por "0", constituirá el mapa de cambios en las escenas bi-temporales.

Para evaluar la bondad de los mapas de cambios, se seleccionan áreas de test para Cambio y No-Cambio supervisadas visualmente (por un experto) sobre las imágenes originales de las dos fechas. Para realizar un análisis preciso se construyen las matrices de error y se calculan la precisión global, las de usuario y productor (error por comisión y omisión), y el coeficiente Kappa [29].

El error por omisión aparece cuando un píxel que pertenece a una determinada categoría, no resulta clasificado en ella (falso negativo). Se plantea como riesgo del productor. Sin embargo, el error por comisión ocurre cuando un píxel resulta clasificado en una categoría y en realidad pertenece a otra (falso positivo). En este caso se plantea como riesgo del usuario.

La precisión global se calcula como el número total de píxeles de test correctamente clasificados, que coinciden con la diagonal principal en la matriz de error, dividido por el número total de píxeles test. El coeficiente Kappa se calcula según (7):

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (7)$$

donde  $r$  es el número de filas de la matriz de error;  $x_{ii}$  es el número de observaciones o píxeles test en la fila  $i$  y en la columna  $i$ ;  $x_{i+}$  y  $x_{+i}$  son los totales marginales en la fila  $i$  y en la columna  $i$ , respectivamente, y  $N$  es el número total de observaciones.

El software de procesado de imagen utilizado es ENVI 4.5 (Environment for Visualizing Images) [30].

## V. RESULTADOS Y DISCUSIÓN

Las Tablas II, III y IV muestran los resultados del análisis de Componentes Principales (ACP) realizado con las escenas 1, 2 y 3 de este estudio. Los vectores propios se exponen normalizados a la unidad, por lo que la suma de los cuadrados de los componentes del vector propio de cada CP, es igual a 1.

Cada valor propio representa la proporción de información que retiene el CP asociado (lo cual es útil para decidir qué componentes son más interesantes para el estudio), en tanto que el vector propio indica la ponderación que debe aplicarse a cada una de las bandas para obtener el CP (equivalentes a los coeficientes de regresión en una transformación lineal estándar, siendo las bandas de la imagen las variables independientes y los CP, las dependientes). El valor absoluto del cada elemento del vector propio indica el grado de contribución de la banda (B) correspondiente al CP definido por la transformación lineal.

TABLA II  
DATOS DEL ACP PARA LA ESCENA 1

	CP1	CP2	CP3	CP4	CP5	CP6	
Vectores propios							
2005	B1	0.400	-0.365	-0.289	0.472	0.388	-0.500
	B2	0.483	-0.397	-0.265	-0.507	0.187	0.497
	B3	0.328	-0.469	0.633	0.097	-0.508	-0.065
	B4	0.423	0.395	-0.157	0.577	-0.241	0.499
2007	B5	0.494	0.466	-0.144	-0.420	-0.309	-0.497
	B6	0.276	0.341	0.632	-0.046	0.635	0.055
	Valor propio	8561.93	1819.93	1305.07	144.17	78.33	17.35
	% Varianza	71.78	15.26	10.94	1.21	0.66	0.14

Como se observa en dichas tablas, los valores propios para los dos primeros CP, son superiores al valor medio calculado a partir dichos valores. Además, CP1 y CP2 reúnen casi el 90% de la información (% varianza), por lo que los otros CP no se tendrán en cuenta. Así, el nuevo espacio transformado de dimensiones CP1 y CP2 (dos frente a las seis iniciales), es el que se considera para seguir analizando. El resto de los CP presentan un porcentaje de varianza menor que la de los dos

primeros componentes, y se considera su información poco útil en este estudio.

TABLA III  
DATOS DEL ACP PARA LA ESCENA 2

	CP1	CP2	CP3	CP4	CP5	CP6	
Vectores propios							
2005	B1	0.348	-0.209	-0.319	-0.303	0.395	-0.697
	B2	0.503	-0.151	-0.434	-0.425	0.354	0.480
	B3	0.302	-0.796	0.331	0.395	0.096	-0.012
	B4	0.374	0.195	-0.078	0.334	-0.722	-0.428
2007	B5	0.495	0.454	-0.076	0.505	0.433	0.318
	B6	0.386	0.234	0.767	0.453	-0.036	0.012
	Valor propio	2974.951	770.179	648.600	155.192	40.292	9.244
	% Varianza	64.69	16.75	14.10	3.37	0.88	0.20

TABLA IV  
DATOS DEL ACP PARA LA ESCENA 3

	CP1	CP2	CP3	CP4	CP5	CP6	
Vectores propios							
2005	B1	0.230	-0.400	-0.280	-0.221	-0.478	0.657
	B2	0.344	-0.483	-0.402	-0.389	0.321	-0.483
	B3	0.529	-0.419	0.620	0.396	0.052	-0.005
	B4	0.312	0.208	-0.323	0.387	-0.634	-0.451
2007	B5	0.416	0.314	-0.431	0.391	0.508	0.363
	B6	0.529	0.538	0.292	-0.583	-0.078	0.014
	Valor propio	5576.612	2419.297	944.935	77.210	31.227	5.446
	% Varianza	61.59	26.72	10.44	0.85	0.34	0.06

A continuación, se analizan para las tres escenas, los valores de las correlaciones entre los componentes transformados (CP) y las bandas originales (B):

- CP1 muestra valores positivos en los casos de las bandas visibles (B1, B2, B4, B5) e infrarrojas (B3, B6) de las dos fechas por lo que no se puede tener en cuenta para evaluar los posibles cambios temporales. Este componente representa principalmente, las características de “no cambio” con varianza común en ambas imágenes bi-temporales.
- CP2 muestra valores negativos en las bandas (B1, B2, B3) de la imagen de 2005 y positivos en las bandas (B4, B5, B6) de la de 2007. Por lo tanto, este componente es el seleccionado para detectar las áreas cambiantes y no cambiantes.

Las imágenes Índices de Cambios (CP2) obtenidas mediante aplicación de (6), para las tres escenas en estudio, se muestran en la Fig. 2.

Para obtener los mapas binarios de cambios, se programa un proceso de umbralización mediante nueve estrategias diferentes [26] [27] [28] para las imágenes CP2.

Los mapas binarios obtenidos son evaluados y las matrices de error resultantes en los tres casos estudiados, se muestran en las Tablas V, VI y VII. En dichas tablas, se indican igualmente, los errores por comisión/omisión, la precisión global y el coeficiente Kappa.




Fig. 2. Imágenes Índices de Cambios obtenidas a partir del segundo Componente Principal. Rango dinámico de 8 bits.

Como puede observarse en la Tabla V, el método de umbralización basado en la entropía de Renyi es el que genera un mapa de cambios más preciso para el caso de la Escena 1. La imagen binaria cambio/no\_cambio (blanco/negro) resultante se muestra en la Fig. 3a.

TABLA V

ESCENA 1. MATRICES DE ERROR PARA LAS CLASES CAMBIO (C) Y NO CAMBIO (NC).  $C_{TEST}$  Y  $NC_{TEST}$  SON LOS PÍXELES DE LAS ÁREAS SUPERVISADAS.  $C_{TH}$  Y  $NC_{TH}$  SON LOS PÍXELES DEL MAPA DE CAMBIOS

Método	MATRICES		ERRORES		Precisión global/ Coef. Kappa	
	$C_{TEST}$	$NC_{TEST}$	Error por Comisión (%)	Error por Omisión (%)		
Entropía	$C_{TH}$	1136	6	0.53	22.19	92.12/
Kapur	$NC_{TH}$	324	2723	10.63	0.22	0.82
Entropía	$C_{TH}$	1384	233	14.41	5.21	92.62/
Li	$NC_{TH}$	76	2496	2.95	8.54	0.84
Entropía	$C_{TH}$	1070	13	1.20	7.44	<b>97.79/</b>
Renyi	$NC_{TH}$	86	3320	2.52	0.39	<b>0.94</b>
Entropía	$C_{TH}$	1199	13	1.07	17.88	93.46/
Yen	$NC_{TH}$	261	2716	8.77	0.48	0.85
Entropía	$C_{TH}$	732	0	0	49.86	82.62/
Shangbhag	$NC_{TH}$	728	2729	21.06	0	0.57
Atributo	$C_{TH}$	1268	26	2.01	13.15	94.80/
Huang	$NC_{TH}$	192	2703	6.63	0.95	0.88
Moment	$C_{TH}$	1268	26	2.01	13.15	94.80/
Tsai	$NC_{TH}$	192	2703	6.63	0.95	0.88
Cluster	$C_{TH}$	1268	26	2.01	13.15	94.80/
Otsu	$NC_{TH}$	192	2703	6.63	0.95	0.88
Cluster	$C_{TH}$	1268	26	2.01	13.15	94.80/
Riddler	$NC_{TH}$	192	2703	6.63	0.95	0.88

A pesar de la eficacia mostrada por el método de umbralización en la generación del mapa binario, es posible mejorar la imagen binaria destacando los cambios más significativos. Se trata de simplificar la imagen y conservar las principales características de la forma de las áreas cambiantes.

Para ello se somete a la imagen a las operaciones morfológicas de apertura y cierre en un ciclo. La operación de apertura consiste en una erosión seguida de una dilatación morfológica. La operación de cierre consiste en una dilatación seguida de una erosión. La erosión elimina islas de píxeles de tamaño menor que el elemento estructurante (kernel). La dilatación rellena huecos de píxeles menor que dicho elemento [31].

En este caso, se utiliza una matriz de dimensiones 3x3 píxeles que recorre toda la imagen en el proceso. El resultado de la operación morfológica es mostrado en la Fig. 3b.

A continuación, se muestran los resultados obtenidos después aplicar la metodología descrita, a las Escenas 2 y 3.

De nuevo, y como puede observarse en las Tablas VI y VII, el método de umbralización basado en la entropía de Renyi, es el que genera mapas de cambios más precisos en los otros dos casos de estudio.




Fig. 3. Escena 1. a) Mapa binario [0,1] de cambios obtenido después de la umbralización. b) Mapa binario [0,1] de cambios obtenido después de la aplicación de las operaciones morfológicas. Se indican los píxeles de cambio (blanco, 1) y de no cambio (negro, 0).

TABLA VI

ESCENA 2. MATRICES DE ERROR PARA LAS CLASES CAMBIO (C) Y NO CAMBIO (NC).  $C_{TEST}$  Y  $NC_{TEST}$  SON LOS PÍXELES DE LAS ÁREAS SUPERVISADAS.  $C_{TH}$  Y  $NC_{TH}$  SON LOS PÍXELES DEL MAPA DE CAMBIOS

Método	MATRICES		ERRORES		Precisión global/ Coef. Kappa	
	$C_{TEST}$	$NC_{TEST}$	Error por Comisión (%)	Error por Omisión (%)		
Entropía	$C_{TH}$	1760	9	0.51	0	99.80/
Kapur	$NC_{TH}$	0	2652	0	0.34	0.99
Entropía	$C_{TH}$	1760	1177	40.07	0	73.38/
Li	$NC_{TH}$	0	1484	0	44.23	0.50
Entropía	$C_{TH}$	1760	9	0.51	0	<b>99.84/</b>
Renyi	$NC_{TH}$	0	2652	0	0.34	<b>0.99</b>
Entropía	$C_{TH}$	1760	7	0.40	0	99.80/
Yen	$NC_{TH}$	0	2654	0	0.26	0.99
Entropía	$C_{TH}$	1194	0	0	32.16	87.20/
Shangbhag	$NC_{TH}$	566	2661	17.54	0	0.72
Atributo	$C_{TH}$	1760	512	22.54	0	88.42/
Huang	$NC_{TH}$	0	2149	0	19.24	0.77
Moment	$C_{TH}$	1760	512	22.54	0	88.42/
Tsai	$NC_{TH}$	0	2149	0	19.24	0.77
Cluster	$C_{TH}$	1760	512	22.54	0	88.42/
Otsu	$NC_{TH}$	0	2149	0	19.24	0.77
Cluster	$C_{TH}$	1760	512	22.54	0	88.42/
Riddler	$NC_{TH}$	0	2661	0	19.24	0.77

TABLA VII

ESCENA 3. MATRICES DE ERROR PARA LAS CLASES CAMBIO (C) Y NO CAMBIO (NC).  $C_{TEST}$  Y  $NC_{TEST}$  SON LOS PÍXELES DE LAS ÁREAS SUPERVISADAS.  $C_{TH}$  Y  $NC_{TH}$  SON LOS PÍXELES DEL MAPA DE CAMBIOS

Método	MATRICES		ERRORES		Precisión global/ Coef. Kappa	
	$C_{TEST}$	$NC_{TEST}$	Error por Comisión (%)	Error por Omisión (%)		
Entropía	$C_{TH}$	1197	6	0.50	0.66	99.61/
Kapur	$NC_{TH}$	8	2373	0.34	0.25	0.99
Entropía	$C_{TH}$	1200	12	0.99	0.41	99.53/
Li	$NC_{TH}$	5	2367	0.21	0.50	0.99
Entropía	$C_{TH}$	1197	6	0.50	0.66	<b>99.61/</b>
Renyi	$NC_{TH}$	8	2373	0.34	0.25	<b>0.99</b>
Entropía	$C_{TH}$	1197	6	0.50	0.66	99.61/
Yen	$NC_{TH}$	8	2373	0.34	0.25	0.99
Entropía	$C_{TH}$	455	0	0	62.24	79.07/
Shangbhag	$NC_{TH}$	750	2379	23.97	0	0.45
Atributo	$C_{TH}$	1186	0	0	1.58	99.47/
Huang	$NC_{TH}$	19	2379	0.79	0	0.99
Moment	$C_{TH}$	1194	6	0.17	0.91	99.61/
Tsai	$NC_{TH}$	11	2373	0.46	0.10	0.99
Cluster	$C_{TH}$	1188	1	0.08	1.41	99.50/
Otsu	$NC_{TH}$	17	2378	0.71	0.04	0.99
Cluster	$C_{TH}$	1186	0	0	1.58	99.50/
Riddler	$NC_{TH}$	19	22379	0.79	0	0.99

Las imágenes resultantes finales, tras los procesos morfológicos se muestran en las Fig. 4a y 4b.




Fig. 4. Mapas binarios de la Escena 2 (a) y de la Escena 3 (b), donde se indican los píxeles de cambio (blanco, 1) y de no cambio (negro, 0).

## VI. CONCLUSIONES

La aplicación del análisis de Componentes Principales (ACP) para detectar cambios en imágenes multibanda, registradas mediante Teledetección, da buenos resultados. Se confirma como una herramienta útil para la compresión de datos multispectrales sin pérdidas de información significativas.

En el procesado de las imágenes, no es necesario aplicar una estrategia multi-bloque para obtener buenos resultados, como en el caso de [18], lo que incrementaría el número de las etapas metodológicas y por tanto el coste temporal y computacional de todo el proceso.

La transformación conjunta de las dos imágenes bi-temporales de cada área de estudio es una estrategia metodológica adecuada para el caso de imágenes SPOT.

El CP2 permite detectar las diferencias entre imágenes de las dos fechas, con buenos resultados. Esto es debido a que muestra valores en sus elementos, suficientemente dispares en magnitud y signo, en relación con las bandas originales. En [19] se utilizaba para detectar cambios, más de una banda transformada (CP), lo que no es necesario, como se demuestra en el presente trabajo.

Al tratarse de una detección de cambios basado en una metodología preclasificación, no se requiere información de referencia del terreno y además, la precisión en la determinación de cambios no se ve influida por los errores que podrían surgir en un posible proceso de clasificación, como podría ocurrir en la aplicación de metodologías post-clasificación [20] [21].

Los buenos resultados de la evaluación supervisada del estudio, avalan la precisión de la metodología propuesta para los tres casos de estudio.

## REFERENCIAS

- [1] A. Singh, "Digital change detection techniques using remotely-sensed data", *Int. J. Remote Sens.*, vol. 10, no. 6, pp. 989-1003, Jun. 1989, 10.1080/01431168908903939.
- [2] T. Lillesand, R. W. Kiefer and J. Chipman, *Remote Sensing and Image Interpretation*. 7th ed. John Wiley & Sons Ltd, UK, 2015, pp. 582-587.
- [3] D. Lu, P. Mausel, E. Brondizio, and E. Moran, "Change detection techniques", *Int. J. Remote Sens.*, vol. 25, no. 12, pp. 2365-2407, Jun. 2004, 10.1080/0143116031000139863.
- [4] M. Hussain, D. Chen, A. Cheng, H. Wei and D. Stanley, "Change detection from remotely sensed images: From pixel-based to object-based approaches", *ISPRS J. Photogramm. Remote Sens.*, vol. 80, pp. 90-106, Jun. 2013, 10.1016/j.isprsjprs.2013.03.006.
- [5] A.P. Tewkesbury, A. J. Comber, N. J. Tate, A. Lamband and P.F. Fisher, "A critical synthesis of remotely sensed optical image change detection techniques", *Remote Sens. Environ.*, vol. 160, pp. 1-14, Apr. 2015, 10.1016/j.rse.2015.01.006.
- [6] Z. Zhu, "Change detection using Landsat time series: A review of frequencies, preprocessing, algorithms, and applications", *c.*, vol. 130, pp. 370-384, Aug. 2017, 10.1016/j.isprsjprs.2017.06.013.
- [7] M. Ehlers, N. Sofina, Y. Filippovska and M. Kada, "Automated techniques for change detection using combined edge segment texture analysis, GIS, and 3D information", *Global urban monitoring and assessment through Earth observation*, Q. Weng (Ed.), CRC Press, Taylor & Francis Group, 2014, pp. 325-351.
- [8] G. Jianya, S. Haigang, M. Guorui and Z. Qiming, "A Review of Multi-Temporal Remote Sensing Data Change Detection Algorithms", in *Proc. ISPRS Congress*, Beijing, China, 2008, pp. 757-762.
- [9] J. Bonilla, F. Prieto and C. Pérez, "Mass and Volume Estimation of Passion Fruit using Digital Images", *IEEE Latin America Transactions*, vol. 15, no. 2, pp. 275-282, Feb. 2017, 10.1109/TLA.2017.7854623.
- [10] V. A. Ramos, V. Ponomaryov, Y. Shkvarko and R. R. Reyes, "Image Super-Resolution via Block Extraction and Sparse Representation", *IEEE Latin America Transactions*, vol. 15, no. 10, pp. 1977-1982, Oct. 2017, 10.1109/TLA.2017.8071243.
- [11] A. Singh and A. Harrison, "Standardized principal components", *Int. J. Remote Sens.*, vol. 6, no. 6, pp. 883-896, Jun. 1985, 10.1080/01431168508948511.
- [12] M. H. Tangestani and F. Moore "Comparison of Three Principal Component Analysis Techniques to Porphyry Copper Alteration Mapping: A Case Study, Meiduk Area, Kerman, Iran", *Can. J. Remote Sensing*, vol. 27, no. 2, pp. 176-182, Apr. 2001, 10.1080/07038992.2001.10854931.
- [13] R. A. Johnson and D. W. Wichern, *Applied Multivariate Statistical Analysis*. Pearson, Prentice Hall, Upper Saddle River, NJ, USA, 2007, pp. 430-488.
- [14] N. Koutsias, G. Mallinis and M. Karteris, "A forward/backward principal component analysis of Landsat-7 ETM+ data to enhance the spectral signal of burnt surfaces", *ISPRS J. Photogramm. Remote Sens.*, vol. 64, pp. 37-46, Jan. 2009, 10.1016/j.isprsjprs.2008.06.004.
- [15] J. A. Morales and E. A. Orduña, "Patterns Extraction for Lightning Transmission Lines Protection Based on Principal Component Analysis", *IEEE Latin America Transactions*, vol. 11, no. 1, pp. 518-524, Feb. 2013, 10.1109/TLA.2013.6502855.
- [16] L. I. Kuncheva and W. J. Faithfull, "PCA feature extraction for change detection in multidimensional unlabeled data", *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 1, pp. 69-80, Jan. 2014, 10.1109/TNNLS.2013.2248094.
- [17] M. Ilsever and C. Ünsalan, *Two Dimensional Change Detection Methods. Remote Sensing Applications*, Berlin/Heidelberg, Germany, Springer, 2012, pp. 23-34.
- [18] B. Qiu, V. Prinnet, E. Perrier and O. Monga, "Multi-block PCA method for image change detection", in *Proc. 12th International Conference on Image Analysis and Processing, ICIAP*, 2003, pp. 385-390.
- [19] C. Munyati, "Use of Principal Component Analysis (PCA) of remote sensing images in wetland change detection on the Kafue Flats, Zambia", *Geocarto International*, vol. 19, no. 3, pp. 11-22, Sep. 2004, 10.1080/10106040408542313.
- [20] J. S. Deng, K. Wang, Y.H. Deng and G. J. Qi, "PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data", *Int. J. Remote Sens.*, vol. 29, no. 16, pp. 4823-4838, Aug. 2008, 10.1080/01431160801950162.
- [21] P. Srestasathien, S. Lawawirojwong, N. Soontranon and P. Rakwatin, "Unsupervised ensemble change detection using kernel PCA", in *Proc. 36th Asian Conference on Remote Sensing: Fostering Resilient Growth in Asian, ACRS*, 2015.
- [22] O. Yousif and Y. Ban, "Improving urban change detection from multitemporal SAR images using PCA-NLM", *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 4, pp. 2032-2041, Apr. 2013, 10.1109/TGRS.2013.2245900.
- [23] S. Marchesi, F. Bovolo, and L. Bruzzone, "A context-sensitive technique robust to registration noise for change detection in VHR multispectral images", *IEEE Trans. Image Process.*, vol. 19, no. 7, pp. 1877-1889, Jul. 2010, 10.1109/TIP.2010.2045070.

- [24] M. El Hajj, A. Bégué, B. Lafrance, O. Hagolle, G. Dedieu, and M. Rumeau, "Relative radiometric normalization and atmospheric correction of a SPOT 5 time series", *Sensors*, vol. 8, no. 4, pp. 2774–2791, Apr. 2008, 10.3390/s8042774.
- [25] R. P. Gupta, R. K. Tiwari, V. Saini and N. Srivastava. "A Simplified Approach for Interpreting Principal Component Images". *Advances in Remote Sensing*, vol. 2, pp. 111–119, May. 2013, 10.4236/ars.2013.22015.
- [26] P. Sahoo, C. Wilkins and J. Yeager, "Threshold selection using Renyi's entropy", *Pattern Recognition*, vol. 30, no. 1, pp. 71–84, Jan. 1997, 10.1016/S0031-3203(96)00065-9.
- [27] M. Sezgin and B. Sankur, "Survey over image thresholding techniques and quantitative performance evaluation", *Journal of Electronic Imaging*, vol. 13, no. 1, pp. 146–165, Jan. 2004, 10.1117/1.1631315.
- [28] I. Molina, E. Martínez, A. Arquero, G. Pajares and J. Sanchez, "Evaluation of a Change Detection Methodology by Means of Binary Thresholding Algorithms and Informational Fusion Processes", *Sensors*, vol. 12, pp. 3528–3561, Mar. 2012, 10.3390/s120303528.
- [29] R. G. Congalton and K. Green, *Assessing the Accuracy of Remotely Sensed Data - Principles and Practices*. 2<sup>nd</sup>. ed. NY, USA, CRC Press, Taylor & Francis Group, 2009, pp. 159–170.
- [30] ENVIimage analysis software  
<https://www.harrisgeospatial.com/Software-Technology/ENVI> (accessed Oct. 2018)
- [31] P. Soille. *Morphological image analysis: principles and applications*. Berlin/Heidelberg, Germany, Springer-Verlag, 2003, pp. 63–137.



**Mª Carmen Morillo-Balsera** se doctoró en Ciencias Matemáticas por la Universidad Politécnica de Madrid (España) en junio de 1999. Actualmente es Profesora Titular de Universidad en el Departamento de Ingeniería Topográfica y Cartografía de la Universidad Politécnica de Madrid (España). Sus intereses en investigación se orientan en el área de procesado de imagen, geoestadística, análisis espacial y aplicaciones.



**Estibaliz Martínez-Izquierdo** se doctoró en 1989 en Ciencias Químicas por la Universidad Complutense de Madrid, España. Es profesora en la Universidad Politécnica de Madrid (España) desde 1984. Actualmente es Profesora Titular de Universidad del Departamento de Arquitectura y Tecnología de Sistemas Informáticos de

la Escuela Superior de Ingenieros Informáticos en dicha Universidad. Su docencia incluye cursos de Sistemas Digitales, Nanotecnología, Teledetección y Procesado de Imagen. Sus intereses en investigación se orientan en el área de Procesado de Imagen en Teledetección, incluyendo la utilización de redes neuronales, algoritmos genéticos, lógica difusa para el análisis e interpretación de imágenes satelitales.



**Iñigo Molina-Sánchez** se graduó en el Grado en Integrated Map and Geoinformation Production en el International Institute for Aerospace Surveys and Earth Sciences (Enschede – The Netherlands) en 1992, y obtuvo el Doctorado por la Universidad Politécnica de Madrid en 2010. Actualmente es Profesor Titular de Universidad en el

Departamento de Ingeniería Topográfica y Cartografía de la Universidad Politécnica de Madrid. Sus intereses en investigación se orientan en el área de las aplicaciones de Teledetección en el dominio óptico y de microondas para extracción de variables biofísica.