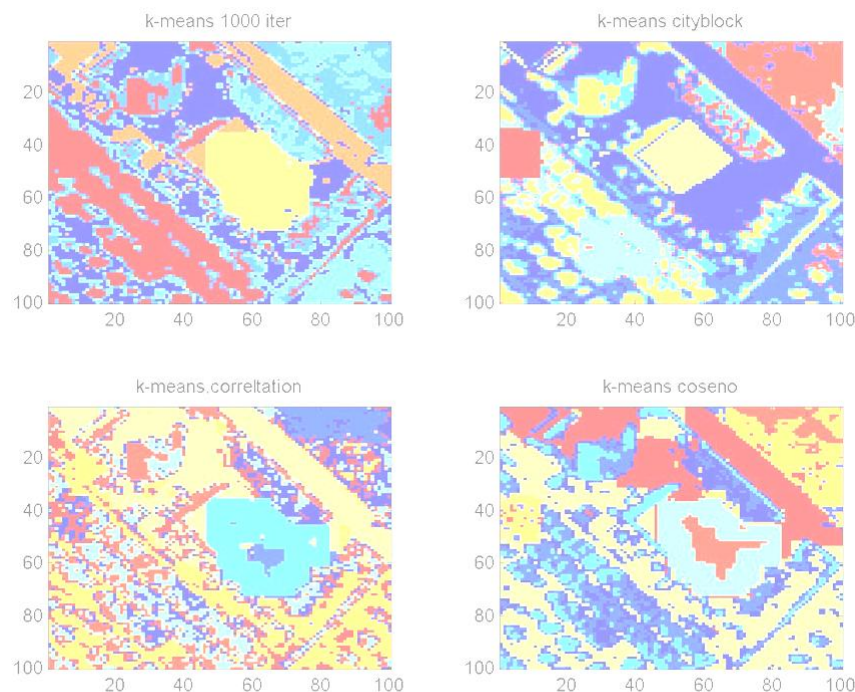


# Detección automática de nuevas construcciones a partir de ortofotos del Instituto Cartográfico Valenciano



Curso académico: 2011-2012

**Máster de Teledetección**

Trabajo realizado por:

**Alfonso Moya Fuero**

Trabajo dirigido por:

**Javier García Haro y Gustavo Cámps Valls**

## **Resumen:**

El objeto de la presente tesina es realizar un estudio sobre las ortofotos del Instituto Cartográfico Valenciano con el fin de detectar nuevas construcciones en diseminado. Para ello se han detectado previamente estos elementos en las ortofotos en dos fechas diferentes (años 2006 y 2008).

El algoritmo de detección se basa en extraer unas bandas para el cálculo a partir de las cuatro que proporciona esta ortofoto (R,G,B e IR). Estas se introducen como dato de entrada en un clasificador no supervisado. Estas bandas que sirven para la detección de cambios son la transformada MADS (Multivariate Alteration Detection), matriz de covariancias y vector de cambios multiespectrales. Antes de calcular las clases en el clasificador se someten las bandas a operaciones de morfología matemática, tales como aperturas, cierres, erosiones, etc.... para conseguir ir aislando estas zonas de cambio y mejorar los resultados del clasificador. Una vez calculadas las clases se usa un criterio de compacidad para determinar cual de ellas se corresponde con la nueva construcción sobre el territorio.

Una vez expuesta la metodología se proponen posibles mejoras a la misma, como la inclusión de nuevas cartografías, otros clasificadores u otras transformadas que podrían mejorar el resultado.

Contenido

1.	<b>Introducción.....</b>	<b>4</b>
1.1	Problemática existente.....	4
1.2	Objetivos .....	4
2.	<b>Estado del arte. ....</b>	<b>5</b>
2.1	Operaciones algebraicas. ....	5
2.2	Métodos basados en transformaciones.....	6
2.3	Técnicas de clasificación. ....	7
2.4	Modelos avanzados.....	9
2.5	Sistemas de información geográficos (SIG).....	9
2.6	Análisis visual .....	10
2.7	Consideraciones sobre los métodos de detección de cambios: .....	11
2.8	Tabla resumen y metodologías empleadas:.....	11
3.	<b>Desarrollo del proyecto. ....</b>	<b>12</b>
3.1	Cartografía empleada.....	12
3.2	Software empleado.....	13
3.2.1	<i>ArcGis 10.0</i> .....	14
3.2.2	<i>ENVI 4.7</i> .....	15
3.2.3	<i>Matlab 2010a</i> . ....	16
3.3	<b>Análisis realizados. ....</b>	<b>16</b>
3.3.1	<i>MAD</i> : .....	17
3.3.2	<i>Normalización</i> . ....	19
3.3.3	<i>Chi cuadrado (Chi<sup>2</sup>)</i> . ....	20
3.3.4	<i>Vector de diferencias y banda de diferencia de NVDI</i> .....	21
3.3.5	<i>Operaciones morfológicas empleadas</i> : .....	22
3.3.6	<i>Tratamiento morfológico a las bandas calculadas</i> . ....	24
3.3.7	<i>Clasificador k-means</i> : .....	26
4.	<b>Conclusiones. ....</b>	<b>31</b>
5.	<b>Bibliografía.....</b>	<b>33</b>
6.	<b>Anexos.....</b>	<b>34</b>
6.1	Anexo 1.- Código fuente de ArcGis. ....	34
6.2	Anexo 2.- Código fuente de ENVI. ....	35
6.3	Anexo 3.- Código fuente Matlab. ....	36
7.	<b>Contenido del CD. ....</b>	<b>40</b>

# 1. Introducción.

## 1.1 Problemática existente

En los últimos años han proliferado por el territorio construcciones fuera de ordenación. Se encuentran en situación legal de fuera de ordenación aquellas construcciones, edificaciones o instalaciones, así como los usos y actividades que existiendo al tiempo de la aprobación de los instrumentos de planeamiento, resulten disconformes con los mismos. Y ello puede ser por varias cuestiones, como por ejemplo, la modificación de la altura máxima permitida o alineaciones a viales, o construir dentro de suelos con algún tipo de figura de protección. Al cabo de cuatro años, el propietario puede darle forma legal a la construcción, ya que la Administración no puede actuar contra ellas y pasan de ser "ilegales" a "legalizables" ( Real Decreto 1492/2011, de 24 de octubre, por el que se aprueba el Reglamento de valoraciones de la Ley de Suelo).

La declaración de fuera de ordenación de un inmueble puede realizarse por el propio Ayuntamiento o a solicitud del interesado, y supone algunas limitaciones de los derechos de los propietarios respecto a dichos inmuebles puesto que sólo podrán realizarse las obras de reparación y conservación que exija la estricta conservación de la habitabilidad o la utilización de los mismos, y aquellas otras actuaciones excepcionalmente autorizadas conforme a lo dispuesto en la Ley, pero dichos inmuebles pueden seguir siendo utilizados por sus propietarios, por lo que estos podrán seguir disfrutando de su vivienda, realizar obras de conservación de la misma, así como llevar a cabo cualquier tipo de negocio jurídico sobre su propiedad, con el conocimiento de la existencia de ciertas limitaciones en su uso, pero con la seguridad jurídica de que ninguna responsabilidad legal se les podrá exigir en el futuro ya que su vivienda ha sido declarada por el Ayuntamiento como fuera de ordenación y, por lo tanto, jurídicamente ya está definida.

Se ha extendido este tipo de construcción ya que era "más barato" para el propietario infringir la ley y construir el bien inmueble, que afrontar unos costosos procesos previos de permisos para este tipo de actuaciones especiales (construcciones no conformes con los Planes de Ordenación) ya que al cabo de pocos años se pueden legalizar. Ha habido permisividad por parte de los Ayuntamientos que no han realizado la tarea de vigilantes del territorio, ya que el acto de legalización repercute positivamente en las arcas municipales.

En esta tesina nos centraremos en las nuevas construcciones fuera de zonas urbanas, es decir, en diseminado.

## 1.2 Objetivos

En el año 2006 el Instituto Cartográfico Valenciano realizó un inventariado de todas las nuevas construcciones en el territorio entre los años 2002 y 2005 a partir de la comparación visual de las ortofotos de dichos años. Estas nuevas construcciones (no necesariamente ilegales ya que habría que consultar las pertinentes licencias, si las tuvieran) han crecido espectacularmente en estos últimos años, creciendo las hectáreas de vivienda diseminada espectacularmente.

En previsión del posible impacto que esta nueva presión urbanística someterá al territorio, la administración debería de contar con alguna herramienta informática que fuera capaz de detectar estas nuevas edificaciones de una manera eficiente, ya que la lentitud de la propia administración en su toma de decisiones beneficia al infractor ya que la

prescripción del delito es más rápida que la pertinente denuncia.

El objeto de esta tesina es hacer un estudio de las diferentes técnicas utilizadas para detectar estos cambios de uso en el territorio con el fin de evaluar su posible aplicación sobre la cartografía del Instituto Cartográfico Valenciano.

## 2. Estado del arte.

En las últimas décadas se han estudiado diferentes técnicas teóricas y prácticas de búsqueda y detección de nuevas construcciones.

Una buena investigación de detección de cambios debe proporcionar la siguiente información [2]:

- Área de cambio y tipo.
- Distribución espacial de los diferentes tipos de cambio
- Según los usos del suelo, la evolución de los mismos.
- Evaluación de la exactitud en la detección de cambios obtenido.

Cuando se implementa una técnica de detección de cambios se suelen seguir los tres pasos siguientes:

- Pre-procesamiento de la imagen con normalizaciones geométricas, radiométricas y atmosféricas.
- Selección de una técnica aplicable a los datos de partida y acorde a los resultados que se esperan obtener (por ejemplo transformada MAD).
- Evaluación de la exactitud.

La precisión de los resultados obtenidos depende de los siguientes factores:

- Georeferenciación precisa entre las diferentes series temporales de datos.
- Calibración y normalización entre las diferentes series temporales de datos.
- Disponibilidad de datos ciertos de campo precisos y fiables.
- Complejidad de la zona de estudio.
- Métodos de detección o algoritmos utilizados.
- Clasificadores y esquemas de detección de cambios.
- Experiencia y habilidades del analista.
- Conocimiento y familiaridad del área de estudio.
- Restricciones de tiempo y coste.

Pasemos a detallar las diferentes técnicas desarrolladas por diferentes autores:

### 2.1 Operaciones algebraicas.

La categoría incluye las operaciones algebraicas entre imágenes como la regresión, ratios entre imágenes, diferenciación de índices de vegetación, análisis vectorial de cambios (ACV) y sustracción del fondo de la imagen. Las características más relevantes se destacan en la tabla 1. Estos algoritmos tienen una característica común, la selección de los umbrales para determinar las áreas modificadas. Estos métodos (excluyendo ACV) son relativamente simples y directos, fáciles de implementar e interpretar, pero éstos por sí mismos no pueden proporcionar las matrices completas de información de cambio. ACV es una extensión conceptual de la diferenciación de imágenes. Este enfoque se basa en

detectar todos los cambios superiores a los umbrales señalados, y puede proporcionar información detallada del cambio. Una desventaja de la categoría de los métodos algebraicos es la dificultad en la selección adecuada de dichos umbrales para identificar las áreas modificadas. En esta categoría, dos aspectos son especialmente críticos: la selección de bandas adecuadas y la selección de umbrales adecuados para identificar las áreas modificadas.

De entre todas las técnicas basadas en el algebra de imágenes, la más usada es la diferencia de imágenes. La resta entre la banda roja visible de las imágenes ha demostrado ser adecuado para la detección de cambios en los ambientes semiáridos y áridos, pero no está claro que esto se cumpla en otros entornos, tales como tropical o regiones húmedas. Diferentes autores han llegado a conclusiones diferentes acerca de qué método proporciona los mejores resultados entre los ratios de imagen, índices de vegetación, la regresión de la imagen, y ACV, ya que los resultados varían en función de las características de las áreas de estudio y los datos utilizados. El método de sustracción de fondo, no es de uso frecuente debido a su poca capacidad de detección de cambios.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Diferencia de imágenes	Resta de dos fechas	Sencillo y de fácil interpretación	No produce una matriz de cambios y necesita seleccionar umbrales	Fácil	Elección correcta de bandas y umbrales
Regresión de imágenes	Establece relaciones entre imágenes temporales, resta ambas aplicando a cada una función de regresión	Reduce los impactos ambientales, atmosféricos y del sensor	Requiere calcular funciones de regresión en cada banda seleccionada	Fácil	Elección correcta de bandas y umbrales así como de las funciones de regresión.
Ratio de imágenes o cociente	Calcula el ratio o cociente entre dos imágenes temporales	Reduce el impacto de las sombras, ángulo solar y topografía	Es criticado la no distribución normal de los resultados.	Fácil	Elección correcta de bandas y umbrales
Diferencia de índices de vegetación	Resta de índices de vegetación entre imágenes temporales	Reduce impactos de iluminación y topografía y marca las diferentes respuestas espectrales	Mejora la eliminación de ruido aleatorio	Fácil	Elección del índice de vegetación a usar y los umbrales
Vector de cambios	Calcula las diferencias espectrales entre las bandas.	Se puede aplicar al número de bandas que se desee. y Proporciona información precisa del cambio producido	Dificultad para detectar la dirección de los cambios de uso producidos	Media	Definir umbrales e identificar trayectorias de cambio.
Sustracción del fondo	Las zonas sin cambio tienen muy baja variación de grises. Un filtro paso-bajo se usa para las variaciones del fondo, que se resta a la original	Fácil de implementar	Baja precisión	Fácil	Determinar imagen de fondo

Tabla 1. Operaciones algebraicas.

## 2.2 Métodos basados en transformaciones.

La categoría incluye las transformaciones PCA (análisis de componentes principales), KT (transformación Tesselated-cap), GS (Gramm-Schmidt) y Chi-cuadrado como se ve en la tabla 2. Una ventaja de estos métodos consiste en la reducción de la redundancia de datos entre las bandas haciendo hincapié en la información extraída de las componentes. Sin embargo, no proporcionan matrices detalladas de cambios y requieren una selección de los umbrales para identificar dichas áreas. Otra desventaja es la dificultad en la interpretación y el etiquetado de la información de cambio de las imágenes transformadas. En la categoría de transformación, PCA y KT son los enfoques más utilizados para la

detección de cambio / no cambio del uso. El método KT, parece útil para muchas aplicaciones de detección de cambios. Una ventaja de la transformación KT sobre PCA es que los coeficientes de transformación son independientes de las escenas de las imágenes, mientras que PCA es dependiente de las escenas de las mismas. Los métodos de la SG y Chi-cuadrado son relativamente menos utilizados en la práctica debido a su complejidad relativa en comparación a PCA y KT. También los métodos de la SG y Chi-cuadrado no están disponibles en la mayor parte del software comercial de procesamiento de imágenes de teledetección.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Análisis de componentes principales (PCA)	Asume que los datos temporales están altamente correlacionados.se aplica a imágenes de dos fechas.	Reduce la redundancia de datos entre todas las bandas y enfatiza la información de las nuevas componentes	PCA es muy dependiente según la escena y es difícil de interpretar y etiquetar. No proporciona una matriz compleja de clases de cambios y requiere de umbrales para las áreas modificadas.	Fácil.	El analista debe decidir que componente detecta mejor el cambio y definir umbrales.
Transformación "Tassel cap (KT)"	Similar al PCA solo que no depende de la escena. Los componentes se basan en el brillo, verdor y humedad de la imagen.	Reduce la redundancia de datos entre todas las bandas y enfatiza la información de las nuevas componentes. Es independiente de la escena.	Difícil de interpretar e etiquetar, no proporciona una matriz de cambios. Previamente hay que corregir atmosféricamente las imágenes de forma muy precisa.	Fácil.	El analista debe decidir que componente detecta mejor el cambio y en que umbrales.
Transformación Gram-Schmidt (GS)	Ortogonaliza vectores bitemporales. Al igual que KT produce tres componentes de brillo, verdor y humedad y una componente de cambio.	La asociación de componentes transformadas a las características de la escena permite extraer información que no es accesible por otras técnicas.	Es difícil extraer más de una sola componente para un tipo de cambio determinado. EL GS se basa en la selección de vectores espectrales.	Media.	Requiere la identificación inicial de los espacios que no cambian.
Chi-cuadrado	$Y=(X-M)T \sum^{-1}(X-M)$ Y: valor digital de la imagen de cambio, X: vector diferencia de las seis bandas temporales en dos fechas, M: vector de los residuos mayores de cada banda, T:traspuesta de la matriz, S21: inversa de la covarianza de las seis bandas	Múltiples bandas son simultáneamente consideradas para generar una única imagen de cambio	Cuando se asume que $Y=0$ representa un pixel sin cambios es falso cuando hay una larga porción de imagen con cambios. Tambien es complicado calcular la dirección de los cambios.	Medio.	Y está distribuida como una variable aleatoria chi-cuadrado con p grados de libertad (p es el número de bandas)

Tabla 2. Métodos de transformaciones.

### 2.3 Técnicas de clasificación.

Esta categoría incluye la post-clasificación, análisis espectral-temporal combinado, el algoritmo EM (expectation-maximization), la detección de cambios sin supervisión, detección de cambios híbrida y técnicas avanzadas de clasificación como Redes Neuronales Artificiales (ANN) resumidos en la tabla 3. Estos métodos se basan en una muestra de entrenamiento de casos bien clasificadas previamente, y en las que la calidad y cantidad de los datos de entrenamiento de la muestra son cruciales para producir resultados fiables. La principal ventaja de estos métodos es la capacidad de proporcionar una matriz de cambios y reducir el impacto externo de la atmósfera y las condiciones

ambientales entre las imágenes multitemporales. Sin embargo, se necesita definir de una forma muy precisa la muestra de entrenamiento y que esta sea lo suficientemente numerosa como para que el clasificador sea eficaz. A menudo es difícil, recopilar estos datos para las series de imágenes históricas. El tiempo de procesamiento y la difícil tarea de producir clasificaciones altamente precisas a menudo conduce a resultados insatisfactorios de detección de cambios, sobre todo cuando no se dispone de unos datos previos clasificados fiables.

Imágenes de transformación, índices de vegetación, métodos avanzados de clasificación, el modelado y la integración de diferentes fuentes de datos a menudo se utilizan para mejorar los resultados. La post-clasificación es un método muy utilizado para la detección de cambios, pero el requisito de detectar en las imágenes estos cambios a menudo afecta gravemente a los resultados. Al contrario, el método híbrido de detección combina las ventajas de los umbrales y los métodos de clasificación. El método con umbrales tales como la diferenciación de la imagen se utilizan a menudo para detectar áreas cambiadas. El método espectro-temporal combina el método de detección de cambios sin supervisión y los anteriores pero se utilizan con menos frecuencia en la práctica debido a la dificultad de identificar y etiquetar las trayectorias de cambio. El método EM no se utiliza normalmente debido a la complejidad de la estimación de una clase conjunta a priori de probabilidad. El enfoque de ANN probablemente produce los mejores resultados de detección de cambios cuando las diferentes clases siguen una distribución normal.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Comparación de Post-clasificación	Clasifica las imágenes temporales separadamente y luego las compara pixel a pixel.	Minimiza los efectos atmosféricos, del sensor y del entorno, y proporciona una matriz de cambios.	Requiere mucho tiempo y experiencia para crear la clasificación. La precisión depende de la calidad de la imagen .	Media.	Dependen de la calidad de los datos de entrenamiento seleccionados.
Análisis combinado espectral de series temporales	Combina en una sola banda los diferentes datos espectrales y los etiqueta por clases.	Simple y requiere poco tiempo de cálculo.	Dificultad para detectar correctamente el número de clases. No proporciona matriz de cambios y hay que indicarle a priori ejemplos de cada clase.	Media.	Etiquetado de las clases.
Detección EM	Utiliza un algoritmo de clasificación Expectativa-Maximización (EM) que estima a priori la probabilidad de cada clase en dos tiempos diferentes.	Este método proporciona más precisión que otros en la detección de cambios.	Requiere estimar a priori el conjunto de la probabilidad de cada clase.	Media.	Estimación de la probabilidad de cada clase.
Detección de cambios no supervisado	Selecciona clases espectrales iguales en la imagen , etiqueta estas mismas clases en la imagen 2 y finalmente proporciona los cambios producidos.	Este método hace uso de la clasificación no supervisada y automatización del proceso.	Dificultad en identificar y etiquetar las direcciones de los cambios.	Media.	Identificar las clases que espectralmente son homogéneas y forman una unidad.
Detección de cambios híbrido	Usa una superposición de una imagen con los píxeles de cambio aislados y los clasifica no supervisadamente, a partir de ello crea una máscara donde se produce el cambio.	Excluye los píxeles que no tienen cambios para reducir los errores.	Requiere la selección de umbrales en las direcciones de cambio entre las clases.	Media.	La selección de umbrales entre las áreas de cambio y no cambio.



Redes neuronales artificiales (ANN)	Los datos de entrada son la información espectral en una serie temporal. Usa un algoritmo de propagación hacia atrás para entrenar la red neuronal.	ANN es un método no supervisado no paramétrico que predice las propiedades de los elementos a partir del entrenamiento.	Necesita mucho tiempo, a priori se desconocen las capas de cambio. No se utiliza frecuentemente en la detección de cambios.	Alta	La dificultad de establecer el número de capas a clasificar y de extraer los datos de entrenamiento.
-------------------------------------	---	---	---	------	--

Tabla 3 Técnicas de clasificación.

## 2.4 Modelos avanzados

Los modelos avanzados de detección de cambios incluyen el modelo de reflectancia de Li-Strahler, modelos espectrales y la estimación de parámetros biofísicos, resumidos en la tabla 4. En estos métodos, los valores de reflectividad de la imagen se convierten a menudo en parámetros físicos o fracciones a través de modelos lineales o no lineales. Los parámetros transformados son más intuitivos para interpretar y mejores para extraer índices de vegetación que los obtenidos a partir de firmas espectrales. La desventaja de estos métodos es el consumo de tiempo y la dificultad de desarrollar modelos adecuados para la conversión de los valores de reflectividad de las imágenes a los parámetros biofísicos. En esta categoría, el análisis lineal de mezcla espectral (LSMA) es el enfoque más utilizado para la detección del cambio de la cubierta terrestre. La dificultad en la aplicación de estos modelos es recopilar una colección de mediciones de campo necesarias y suficientes. Las aplicaciones de estos modelos son a menudo muy costosas en tiempo y en dificultad. Otro hándicap es que solo detectan cambios en la vegetación. La gran ventaja de es su extracción estable y fiable.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Li-Strahler Modelo de reflectividad.	Se utiliza para detectar la corona de coníferas entre imágenes temporales. Devuelve los cambios producidos.	Combina las técnicas de teledetección con las clásicas observaciones de campo. Proporciona patrones de cambio, estadísticas y mapas de cambio.	Necesita muchos datos de campo y solo detecta cambios en la vegetación.	Alta.	Identifica las coronas de la vegetación.
Modelo de mezcla espectral.	Utiliza una mezcla espectral para derivar imágenes fracción y compara las diferencias de clases en las imágenes finales. Utiliza una librería espectral para crear las zonas de entrenamiento.	Las clases resultantes tienen significado biofísico, los resultados son precisos, estables y reproducibles.	Este método está considerado como avanzado y complejo.	Alta.	Identificar los umbrales de cambio entre clases y las zonas de entrenamiento finales.
Método de parámetros biofísicos.	Integra datos biofísicos de campo y de teledetección, clasifica la vegetación según estos parámetros. Normaliza los datos de entrada y los calibra y devuelve los cambios producidos en una serie temporal.	Este método puede detectar con precisión cambios basados en estructuras físicas en la vegetación.	Requiere mucho esfuerzo implementar la normalización y correcciones atmosféricas. Necesita muchos datos de cambio y es solo válido para cambios en la vegetación.	Alta.	Desarrolla modelos de estimación basados en parámetros biofísicos.

Tabla 4 Modelos avanzados.

## 2.5 Sistemas de información geográficos (SIG).

La categoría de cambio basado en el SIG incluyen dos métodos principales denominados comúnmente "SIG integrado" y "Aproximación SIG" (ver tabla 5). La ventaja de usar un

SIG es la capacidad de incorporar los datos de diferentes fuentes en las aplicaciones de detección de cambios. Sin embargo, es habitual que tengan asociadas datos con diferentes precisiones geométricas, y que tengan diferentes formatos que a menudo afectan a los resultados de detección de cambios. Enfoques SIG han demostrado muchas ventajas sobre los métodos tradicionales de detección de cambios. Se pueden incorporar además de los datos de teledetección, cartografías vectoriales, usos del suelo, estadísticas, etc. La mayoría de las aplicaciones de detección basadas en el enfoque de los SIG ha sido desarrolladas en las zonas urbanas. Esto es probablemente porque los métodos tradicionales de detección de cambios a menudo tienen pobres resultados debido a la complejidad de los paisajes urbanos y estos no pueden utilizar eficazmente las múltiples fuentes de datos necesarias para los análisis. Resumiendo, el potencial de los SIG proporciona herramientas prácticas que ayudan a la detección de cambios en ámbitos que tradicionalmente no se habían estudiado. Los SIG también destacan por la capacidad de manejar cantidades ingentes información de una forma eficiente y ligera además de la versatilidad que ofrece a la hora de publicar resultados, realizar estadísticas, etc.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Método integrado de SIG y teledetección.	Integra datos SIG y de teledetección. Explora los resultados dentro del SIG.	Permite el acceso a datos auxiliares para la interpretación. Tiene la capacidad de actualizar los datos de usos del territorio.	El uso de diferentes fuentes de información puede degradar la precisión del resultado final.	Medio.	El uso de diferentes datos con diferentes precisiones. Tienen que estar georeferenciados correctamente.
Aproximación SIG.	Se integran datos históricos con datos topográficos y geológicos. Enmascara los datos para poder medir el grado de cambio entre clases.	Permite la integración de diferentes datos cartográficos.	El uso de diferentes fuentes de información puede degradar la precisión del resultado final.	Medio.	El uso de diferentes datos con diferentes precisiones. Tienen que estar georeferenciados correctamente.

Tabla 5 Sistemas de Información Geográficos (SIG).

## 2.6 Análisis visual

La categoría de análisis visual (ver Tabla 6) se basa en la interpretación directa de datos multitemporales de imágenes compuestas, digitalizando las zonas de cambio. Este método depende de la experiencia del analista y del conocimiento que tenga del área trabajada. La textura, forma y tamaño de los patrones buscados en las imágenes son elementos útiles para la identificación de los mismos en la interpretación visual. Estos elementos no se utilizan a menudo en la detección y análisis debido a la dificultad en la extracción de estos y por la existencia de técnicas no supervisadas. Sin embargo, en la interpretación visual, un analista experto puede incorporar todos estos elementos para ayudarle a tomar decisiones sobre los cambios. La desventaja de este método es el tiempo consumido en grandes áreas de detección y que es difícil obtener altas precisiones en la delimitación de estas áreas. También es difícil obtener la trayectoria de los cambios. La interpretación visual se utiliza ampliamente en diferentes campos, tales como en el inventario de los bosques. Con el rápido desarrollo de las tecnologías informáticas y de teledetección, el procesamiento digital las señales han ido sustituyendo a la interpretación visual. Sin embargo, el procesamiento automático de la imagen no siempre es factible para todos los casos. Por ejemplo, la detección de la explotación forestal selectiva o perturbación es a menudo muy difícil con el tratamiento informático, sin embargo, la interpretación visual tiene la posibilidad de identificar esos cambios por los analistas especializados.

Técnica	Características	Ventajas	Inconvenientes	Dificu.	Factores
Interpretación visual	Se basa en la comparación visual de diferentes bandas en diferentes fechas, de una misma zona en una serie temporal.	Se aprovecha la experiencia del técnico que realiza el trabajo.	El resultado final depende de la experiencia del técnico, y no proporciona datos exactos de las zonas de cambio.	Fácil.	El grado de conocimiento del técnico de los datos a clasificar.

Tabla 6 Análisis Visual.

## 2.7 Consideraciones sobre los métodos de detección de cambios:

Algunos autores hacen otras clasificaciones parecidas, por ejemplo [3] Sui. 2008 distingue las siguientes: comparación directa, clasificación, métodos orientados a objetos, modelos, análisis de series temporales, análisis visual y método híbrido. La mayoría de estudios han concluido de que no hay una metodología específica única que sea apropiada a todos los casos de estudio [3].

Todos los esfuerzos hoy en día se centran en aproximaciones automatizadas basadas en analizar imágenes multispectrales en un contexto de temporalidad. Digitalizar a mano las coberturas cambiantes o levantar por topografía clásica los cambios producen un resultado de alta precisión y calidad pero su alto coste material como en tiempo así como la velocidad a la que se producen estos cambios [4] hacen que se tenga que automatizar estos procesos de actualización [5].

A pesar de que ha aumentado mucho la resolución de las imágenes espectrales utilizadas sigue siendo una tarea complicada la detección automatizada de estas alteraciones. Las diferencias de luz, atmosféricas o partículas en suspensión de las diferentes capturas dificultan la tarea [6]. A la vez, la complejidad de los entornos urbanos así como su reflectividad, forma y tamaño multiplican exponencialmente la variedad de casos a identificar [7].

Actualmente la nueva adquisición de datos como el LIDAR [8] o la inventariación de coberturas de usos del suelo [9] son integradas junto a datos de los objetos como color, tamaño, forma y textura, así como información topológica acerca de los colindantes para crear modelos de aproximación [10].

## 2.8 Tabla resumen y metodologías empleadas:

De entre todas las técnicas expuestas anteriormente se detallan en la tabla 7 las utilizadas en este trabajo:

Grupo	Técnica
<b>Análisis visual</b>	Análisis visual
<b>SIG</b>	Método integrado de SIG y teledetección.
<b>Algebra</b>	Diferenciación de imágenes
	Regresión de imágenes
	Ratio de imágenes o cociente
	Diferencia de índices de vegetación
	Vector de cambios
<b>Transformación</b>	Chi-cuadrado
	Transformada MAD (Multivariate Alteration Detection).
<b>Clasificación</b>	Método no supervisado (K-means)

Tabla 7 Técnicas empleadas.

Además de estas técnicas, y como herramienta de soporte a los métodos de extracción de bandas para la clasificación, se han utilizado operaciones morfológicas en dichas bandas para mejorar la clasificación de los cambios. Estas operaciones que se detallarán mas adelante son aperturas, cierres, dilataciones y erosiones utilizando como elementos estructurales rectángulos y rombos, ya que son los elementos que más se parecen geoméricamente a las nuevas construcciones.

### 3. Desarrollo del proyecto.

Vamos a realizar algunos de los análisis propuestos anteriormente para demostrar su aplicación en la detección de nuevas construcciones en el territorio. La metodología seguida a grandes rasgos es la siguiente:

- Detección de nuevas construcciones mediante una comparación visual entre dos ortofotos de dos fechas diferentes.
- Recorte de las mismas manteniendo la misma georeferenciación de los píxeles comunes.
- Normalización radiométrica.
- Extracción de bandas como entradas de los algoritmos de clasificación, como la diferencia de NVDI, Chi cuadrado, vector de cambios y transformada MAD.
- Operaciones morfológicas sobre las bandas extraídas como aperturas, cierres, erosiones y dilataciones con el fin de asilar los cambios buscados.
- Emplear un clasificador para agrupar en una o varias clases los objetos a identificar.
- Detección de la clase que recoge la nueva edificación del resto en base a criterios de compacidad.

#### 3.1 Cartografía empleada.

Los datos de partida son dos ortofotomapas de dos años diferentes para poder localizar sobre ellos nuevas construcciones en el territorio y así poder comprobar diferentes metodologías de detección de cambios. Las fechas de los vuelos son el año 2006 y el 2008. La campañas de vuelos fotogramétricos para la toma de imágenes aéreas dura aproximadamente un mes e intenta preservar la calidad de las mismas, volando por ejemplo en días claros sin nubes y en las horas centrales del día par que las sombras sean lo menos alargadas posible. La precisión de esta cartografía es la correspondiente a la escala 1:5.000, es decir, 1 metro, pero las imágenes tienen una resolución mayor, de 0,5 metros.

Las ortofotos pertenecen al Instituto Cartográfico Valenciano pudiéndose descargar de su portal cartográfico Terrasit (<http://terrasit.gva.es>). Se han elegido estas dos fechas porque a partir del año 2005 se incluye en los vuelos fotogramétricos un sensor de infrarrojo, obteniendo además de las tres bandas correspondientes en el espectro visible (RGB) una cuarta perteneciente al infrarrojo (IR).

A continuación vemos dos ejemplos de una zona con nuevas construcciones, en la ortofoto del año 2005 se observan unas parcelas sin construir y en la ortofoto de 2007 se observan las nuevas construcciones:




Figura 1 Ortofoto de 2006 y de 2008.

- Ortofoto escala 1:5.000 del año 2006 del Instituto Cartográfico Valenciano.

<b>Abstract</b>	Ortofoto de la Comunidad Autónoma de Valencia, zona Valencia correspondiente al año 2006. Con tamaño de pixel de 50 centímetros y distribuida por hojas del MTN50.
<b>Descripción</b>	El producto inicial es el vuelo fotogramétrico que realizó el Instituto Cartográfico Valenciano en el año 2006 (10 julio - 10 agosto). Tamaño del píxel 40 cm GSD. Altura media del vuelo sobre el terreno de 4.500 m. (14.800 pies) sobre la cota media del terreno. El vuelo consta de 4776 imágenes agrupadas en 99 pasadas. El recubrimiento longitudinal es del 60% y 30% de recubrimiento transversal. Cámara: UltraCamD de Vexcel (Focal:101.4 mm). El formato de las imágenes digitales es de 11.500 x 7.500 píxeles. Permite la generación de imágenes por cada fotograma en RGB (Rojo, Verde, Azul) y en IRG (Infrarrojo, Rojo, Verde) con una profundidad radiométrica de 16 bits por cada canal
<b>Formatos</b>	TIFF, ECW
<b>SRS</b>	EPSG:25830 (ETRS89 UTM huso 30 zona N)
<b>Bandas</b>	4: R,G,B,IR

Tabla 8 Datos técnicos ortofoto de 2006.

- Ortofoto escala 1:5.000 del año 2008 del Instituto Cartográfico Valenciano.

<b>Abstract</b>	Ortofoto de la Comunidad Autónoma de Valencia, zona Valencia correspondiente al año 2008. Con tamaño de pixel de 50 centímetros y distribuida por hojas del MTN50.
<b>Descripción</b>	Vuelo fotogramétrico digital de zona urbana de Valencia para el proyecto PNOA-VALENCIA. GSD 40 cm. Volado con avión Cessna 402-C ECDKP y avión PIPER OH-UTI. Fechas de vuelo del 26 de junio al 02 de julio de 2008. Recubrimiento longitudinal mínimo del 60%. Recubrimiento transversal mínimo 36% (en núcleos urbanos 60%). Cámara digital VEXCEL ULTRACAMD (focal: 101.4 mm.) Postproceso de los datos GPS del avión y de la estación de referencia para calcular la trayectoria del avión e integración de los datos INS. Conocidas las posiciones y ángulos del avión a intervalos de 0.5 segundos se interpolan para cada tiempo en que se ha efectuado una fotografía las coordenadas y ángulos de la misma. Cámara digital Vexcel Ultracam D focal = 101.400 mm. píxel sensor pancromático = 0.009 mm. píxel sensor multiespectral = 0.028 mm.
<b>Formatos</b>	TIFF, ECW
<b>SRS</b>	EPSG:25830 (ETRS89 UTM huso 30 zona N)
<b>Bandas</b>	4: R,G,B,IR

Tabla 9 Datos técnicos ortofoto de 2008.

## 3.2 Software empleado.

Para el tratamiento de dicha información y la aplicación de las técnicas de detección se han empleado tres software comerciales, ArcGis de la casa Esri, ENVI de la casa ITTVIS y Matlab de la casa Mathworks.

A continuación se explica que tarea se ha realizado con cada uno de ellos.

### 3.2.1 ArcGis 10.0

Se ha empleado este software de Sistemas de información geográfico para la detección visual de las nuevas construcciones en diseminado. Se han superpuesto ambas imágenes (que están exactamente georeferenciadas) y activando y desactivando capas, se delinea un punto encima de cada nuevo elemento detectado.

La calidad en la georeferenciación está garantizando ya que el Instituto Cartográfico Valenciano realiza un control de calidad sobre la aerotriangulación calculada para la rectificación de dichas ortofotos. Se apoya en la Red Geodésica de Cuarto Orden de la Comunidad Valenciana y en los datos de campo tomados los días del vuelo fotogramétrico. En ambos vuelos, después de compensar todos los puntos elegidos para el apoyo se han obtenido precisiones superiores al metro, siendo estos válidos para la escala de representación 1:5.000. Garantizada la calidad métrica, se suministran las imágenes con una resolución de 0.5 metros, ayudando la claridad de interpretación de lo representado.

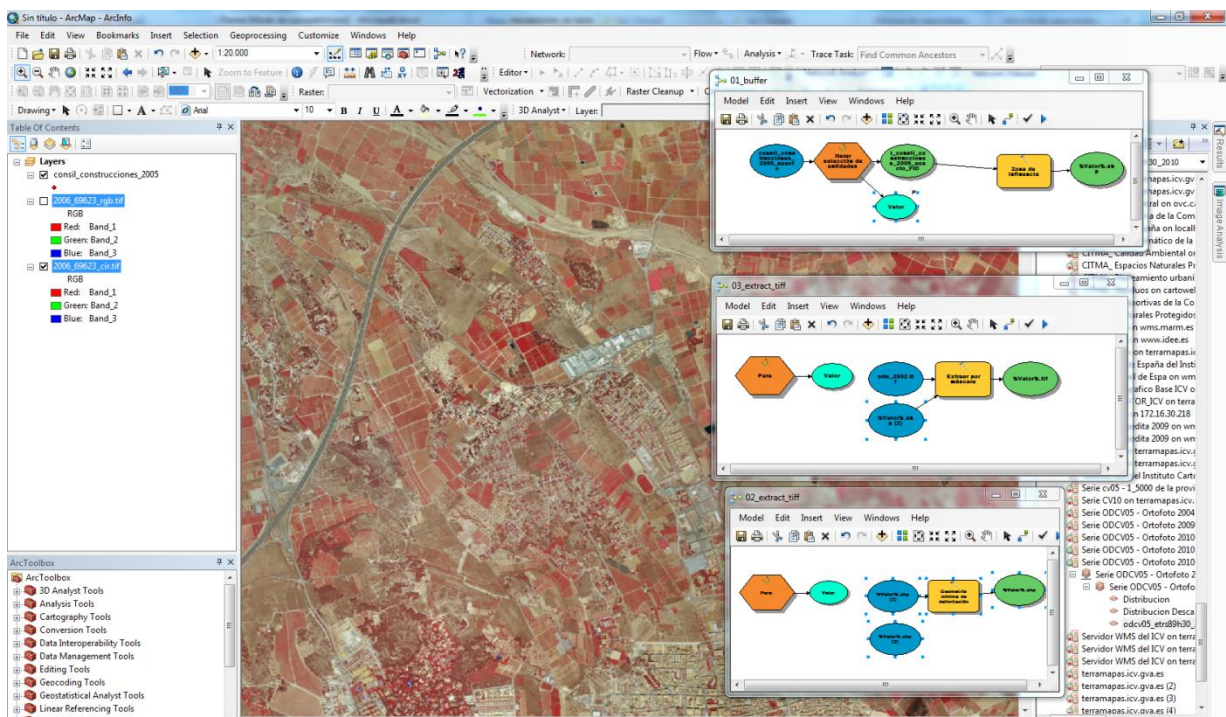


Figura 2 Entorno de trabajo Arcgis.

Se ha obtenido una muestra representativa y extensa para tener una muestra lo suficientemente extensa como para tener diferentes tipos de construcciones, de tamaños, formas y texturas. A continuación se procede a efectuar un recorte de las imágenes de 50 metros lado, tomando como centro el punto delimitado, es decir, de la nueva construcción detectada. Las imágenes resultantes tiene una dimensión de 100 x 100 píxeles.

### 3.2.2 ENVI 4.7

Una vez se ha recortado cada una de las imágenes que contienen una nueva construcción se le ha aplicado un tratamiento a las mismas con una rutina de IDL. (El código fuente se adjunta en el anexo 2), con el objetivo de crear una única imagen con 16 bandas, que serán la base para los posteriores tratamientos en Matlab.

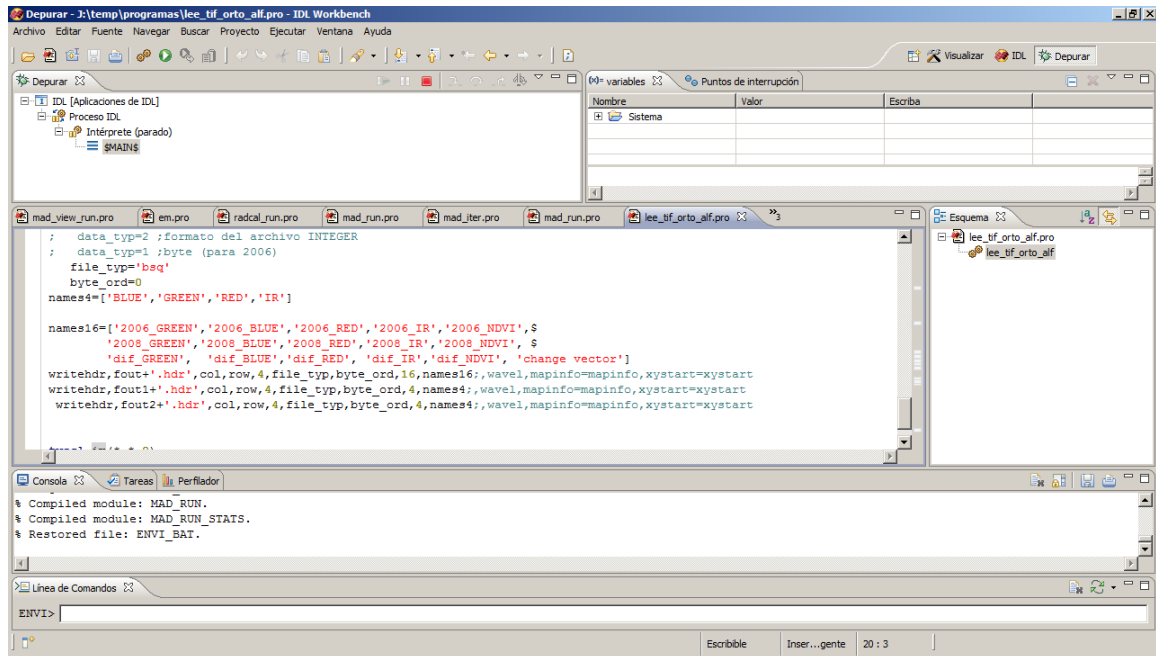


Figura 3. Entorno de trabajo ENVI+IDL

El formato de entrada es el TIFF (elegido por no tener compresión a diferencia del ECW, así no hay pérdida de información). Cada uno de los ficheros tiene como formato de salida el de ENVI bsq y viene acompañado de un fichero de cabeceras .hdr que indica todas las descripciones de las bandas:

```

ENVI
description = {File created using an IDL program }
samples = 100
lines = 100
bands = 16
header offset = 0
file type = ENVI Standard
data type = 4
interleave =bsq
sensor type = Unknown
byte order = 0
band names=
{2006_GREEN,2006_BLUE,2006_RED,2006_IR,2006_NDVI,2008_GREEN,2008_BLUE,2008_RED,2008_IR,2008_NDVI,dif_
GREEN,dif_BLUE,dif_RED,dif_IR,dif_NDVI,change vector}

```

Las bandas son:

- 2006\_GREEN: Banda verde del RGB del año 2006.
- 2006\_BLUE: Banda azul del RGB del año 2006.
- 2006\_RED: Banda roja del RGB del año 2006.
- 2006\_IR: Banda del infrarrojo del año 2006.
- 2006\_NDVI: Índice de vegetación NVDI del año 2006.
- 2008\_GREEN: Banda verde del RGB del año 2008.
- 2008\_BLUE: Banda azul del RGB del año 2008.
- 2008\_RED: Banda roja del RGB del año 2008.
- 2008\_IR: Banda del infrarrojo del año 2008.

- 2008\_NDVI: Índice de vegetación NVDI del año 2008.
- dif\_GREEN: Diferencia entre la banda 2006\_GREEN y 2008\_GREEN.
- dif\_BLUE: Diferencia entre la banda 2006\_BLUE y 2008\_BLUE.
- dif\_RED: Diferencia entre la banda 2006\_RED y 2008\_RED.
- dif\_IR: Diferencia entre la banda 2006\_IR y 2008\_IR.
- dif\_NDVI: Diferencia entre la banda 2006\_NVDI y 2008\_NVDI.
- change vector:

Este sería el aspecto al cargarlo en ENVI:

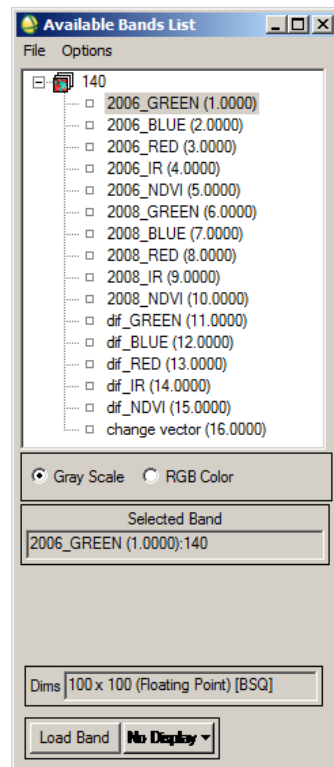


Figura 4. Bandas de salida cargadas en ENVI.

Con esta rutina se han exportado las 122 imágenes de muestra que se han capturado en el anterior proceso.

### 3.2.3 Matlab 2010a.

En Matlab se ha utilizado como herramienta principal la Image Toolbox, que proporciona un conjunto completo de algoritmos de referencia-estándar y herramientas gráficas para el procesamiento, el análisis y la visualización de imágenes y el desarrollo de algoritmos.

Para poder leer los datos de entrada y poder escribir los resultados desde Matlab se ha utilizado dos funciones. La primera lee el formato HDR de ENVI y lo convierte en una matriz de Matlab. La segunda función es para escribir los resultados en formato HDR ya que así están disponibles para su visualización y uso en otros programas.

En Matlab se han programado las rutinas que desarrollan el resto de funciones y análisis objeto de esta tesina, se van a detallar más en profundidad a continuación. Todo el código fuente, al igual que en los anteriores casos se encuentra disponible en el Anexo 3.

## 3.3 Análisis realizados.

Una vez tenemos todos los recortes de la ortofoto en la que hay una nueva construcción,



vamos a empezar a tratar la información para que sea posible ejecutar diferentes análisis morfológicos sobre los mismos.

Para poder aplicar estas operaciones morfológicas primero tenemos que calcular las bandas de la imagen que mejor reflejen los cambios producidos. Para ello vamos a basar el trabajo en cuatro bandas principalmente:

- Transformada IRMAD.
- Vector de cambios.
- Chi cuadrado.
- Diferencia de NVDI

Una vez calculadas las combinaremos en una única estructura de datos a la que aplicaremos el clasificador K-means para intentar aislar en un clúster o clase el cambio de nuevas construcciones y verificar la bondad del método así como posibles mejoras a introducir.

A continuación se explica la obtención de cada una de ellas así como su fundamento. Para ello cogeremos la imagen número 57 incluida en el directorio de resultados del Cd que acompaña la tesina.

### 3.3.1 MAD:

El método [11] “*The Regularized Iteratively Reweighted MAD Method for Change Detection in Multi- and Hyperspectral Data*” se ha utilizado para la extracción de una banda basada en dicha transformada y que servirá como dato de entrada para el clasificador..

En este trabajo se ha aplicado una nueva transformación ortogonal, la transformación (MAD, multivariate alteration detection), basado en un análisis multivariante que establece la correlación canónica de los cambios entre las bandas.

A diferencia de los sistemas tradicionales de detección de cambios univariados este esquema transforma dos series de observaciones multivariantes (por ejemplo, dos imágenes multispectrales de satélite que cubren la misma área geográfica adquirida en diferentes fechas) en una diferencia entre dos combinaciones lineales de las variables originales, estas diferencias cuantifican el cambio máximo (es decir, la diferencia que explica la varianza máxima) en todas las variables simultáneamente.

La transformación MAD es invariante a escala lineal. Puede ser usada de forma iterativa. En primer lugar, se puede utilizar para detectar valores atípicos o el ruido y en una segunda iteración, se puede utilizar para realizar la detección de cambio real después de la acción apropiada en los valores atípicos o de ruido (corrección radiométrica de los mismos).

También, si el usuario tiene información adicional tal como la posición geográfica de ciertos cambios de interés que aparecen en ciertas bandas solamente, este método puede ser aplicado a cualquier subconjunto espacial y/o espectral de los datos completos para dirigir el análisis en la manera deseada. Con el fin de obtener una representación más espacialmente coherente del cambio detectado, como el obtenido a partir del análisis MAD, después del procesamiento por medio de un factor mínimo/máximo de autocorrelación (MAF) es cuando se realiza la transformación de las variables aleatorias MAD.

Considerando que la transformación más utilizada tradicionalmente son las componentes

principales (PCA), esta transformación optimiza la varianza de los datos en cada nuevo componente de la transformación MAD y optimiza la autocorrelación representada por cada componente. Este post-procesamiento introduce un nuevo elemento espacial en este esquema de detección de cambio que es muy relevante para los datos de imagen. Debido a su capacidad para detectar cambios en los canales de manera simultánea, la transformación y el post-procesamiento MAD/MAF es aún más útil cuando se aplica a un mayor número de bandas en las que se aprecien los cambios.

Los datos de entrada para la extracción de la transformada MADS son las bandas R,G,B e IR correctamente georreferenciadas pixel a pixel.

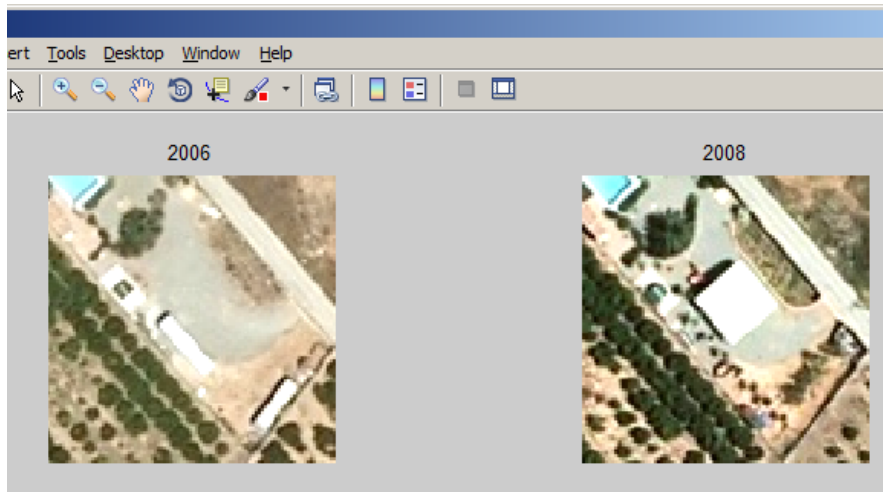


Figura 5 Datos de entrada 2006 y 2008 en RGB

En la siguiente figura se muestra la regresión entre las bandas de entrada usadas para obtener las transformadas MAD.




Figura 6 Regresión de los pixeles de las banda usadas para la transformada MAD.

Una vez calculado la transformada MAD se muestra en la figura 6 el resultado:




Figura 8 Transformada MAD para la banda 4 en escala de grises

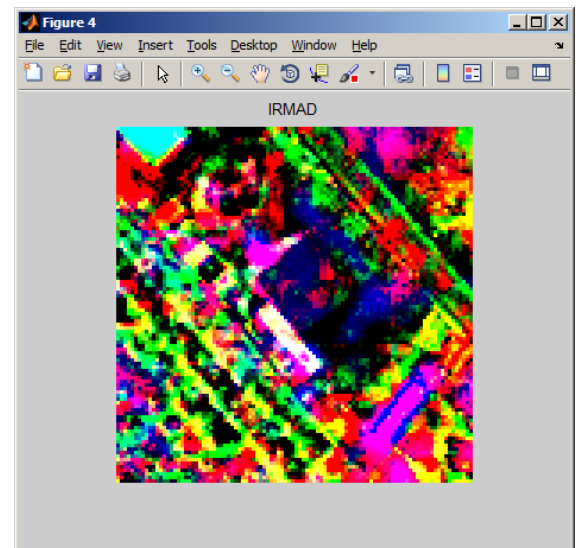


Figura 7 Transformada MAD bandas 1,2 y 3.

### 3.3.2 Normalización.

Dado que el estudio se basa en un estudio multitemporal de imágenes hay que asegurarse que ambas fechas son “comparables”, es decir, que los cambios observados en ambas se deban exclusivamente a variaciones del territorio y no tenga “ruidos” causados por cambios atmosféricos, diferencia del sensor de toma de datos o errores en la correcta georeferenciación.

Los datos están perfectamente georeferenciados ya que esta precisión la garantiza el Instituto Cartográfico Valenciano, ya que su control de calidad desecha las imágenes con nubes o borrosas, y el apoyo fotogramétrico realizado para el cálculo de dicha ortofoto garantiza los 0,5 metros de pixel de las imágenes.

Falta realizar una Normalización Radiométrica de los datos para eliminar los errores de sensor (calibrado del detector, filtrado de los datos, estabilidad de la plataforma) y los errores causados por las condiciones topográficas, atmosféricas, sombras y efectos de superficies adyacentes.

El método propuesto ha utilizado un enfoque denominado *Normalización de Imágenes*. Consiste en elegir una escena como referencia que contenga el mayor número de elementos con reflectividades invariantes (arena, asfalto, barbecho,...) y lo menor afectada posible por las condiciones atmosféricas. Con ello también se consigue reducir las diferencias de iluminación entre secuencias y la degradación temporal en la respuesta del sensor.

Se ha aplicado la técnica de detección multivariada de alteraciones (*Multivariate Alteration Detection MAD*) [12]. Esta técnica permite estimar, de un modo casi automático, las áreas radiométricas invariantes a partir de técnicas multivariadas.

Aplicando el algoritmo correspondiente la normalización producida de la imagen del 2008 con respecto a la del 2006 sería:



Figura 9 Imagen de 2008 normalizada.

Vemos como se ha homogeneizado con respecto a la de entrada del 2006. Los valores de reflectividad de 2006 son ahora comparables con los de 2008 normalizada, siguen la misma distribución estadística (media y desviación típica), se reducen los efectos atmosféricos y de calibrado del sensor entre ambas fechas.

### 3.3.3 Chi cuadrado ( $\chi^2$ ).

Entre las propiedades que tienen las componentes MAD una es la ortogonalidad no correlacionada, cuyas varianzas se guardan en una matriz. La correlación mide el valor y dirección de esa asociación de píxeles de una manera lineal, es decir, si en la imagen de entrada va aumentando un valor, en la imagen homónima también irá aumentando de la misma manera, si no es que hay cambios entre los píxeles y no hay correlación.

Esa matriz tiene la siguiente representación:

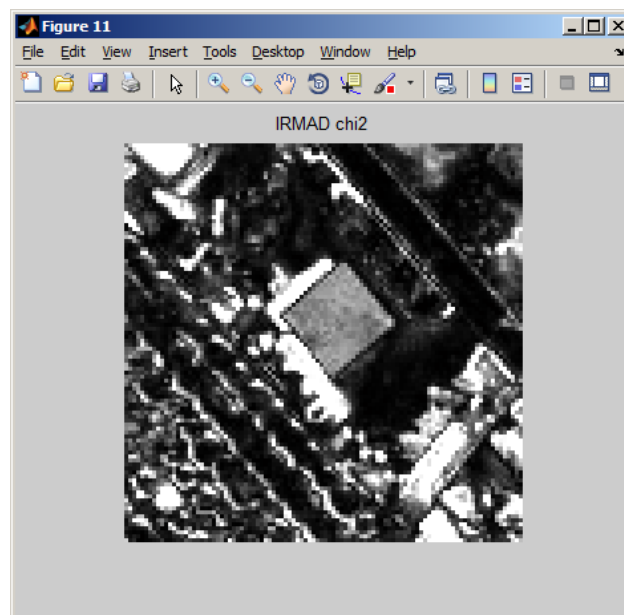


Figura 10 Imagen de la Chi 2 (covarianzas).

Ya tenemos otra banda a utilizar en el clasificador, se aprecia como en la zona de la nueva construcción hay una homogeneización de esos valores.

### 3.3.4 Vector de diferencias y banda de diferencia de NVDI.

Las siguientes dos bandas también las incluiremos en el clasificador k-means. La primera es el vector de diferencias, es una resta multispectral que se ha calculado con la siguiente fórmula:

Vector\_diferencias= \_\_\_\_\_

A partir de la diferencia entre bandas del Rojo, NVDI e Infrarrojo. El resultado es el siguiente:



Figura 11 Vector de diferencias multispectral.

El vector de diferencia del NVDI se calcula restando ese índice de vegetación para cada imagen en su año correspondiente, como vemos en la figura 12:




Figura 12 NVDI de 2006, 2008 y la diferencia entre ambos.

### 3.3.5 Operaciones morfológicas empleadas:

Ya tenemos extraídas para cada serie histórica todas esas bandas anteriormente descritas, utilizaremos operaciones morfológicas para adecuar la información mejor al clasificador, nuestro objetivo es ir aislando cada vez más esas nuevas construcciones.

La morfología matemática aplicada a las imágenes es una técnica de procesado no lineal que permite extraer información sobre la geometría de los objetos (forma y estructura). Sus principales ventajas son:

- Permite extraer componentes de la imagen que son útiles en la representación y descripción de la forma de las regiones, (fronteras, esqueletos,...).
- Permite obtener características relevantes de los objetos en la imagen, (tamaños, formas,...).

El procesado morfológico permite transformar la forma o la estructura de los objetos en una imagen.

Existen varios tipos posibles de operaciones morfológicas:

- Morfología binaria (es la más frecuente).
- Morfología de niveles de gris
- Morfología de imágenes poli cromáticas.

Los usos más frecuentes son, por ejemplo, en post-proceso después de una segmentación, o en pre-proceso antes de un reconocimiento de objetos (como es nuestro caso).

Los fundamentos del análisis y procesado morfológico se basan en el álgebra de conjuntos y en la topología. Para ello los componentes principales son:

- Conjuntos. Cada conjunto representa la forma de los objetos en una imagen. Cualquier transformación sobre un conjunto define una nueva imagen.
- Operadores Morfológicos (dilatación, erosión, apertura/cierre). Pueden ser extensivos, antiextensivos o idempotentes.
- Elementos Estructurantes (EE). Permiten examinar la estructura geométrica de una imagen usando como sonda un patrón de ajuste que se denomina elemento estructurante. La forma y tamaño del EE caracteriza las formas de los objetos presentes en una imagen permiten determinar la estructura de un conjunto. El EE se maneja de modo análogo a una máscara de convolución, basada en operaciones aritméticas

Veamos estos elementos y su aplicación a nuestras bandas antes calculadas.

#### — *Dilatación:*

La salida de la dilatación es el conjunto de puntos barridos por el centro del EE mientras algún punto de entrada coincide con alguno del EE. Alternativamente (véase figura 13), La dilatación puede interpretarse como el resultado de reemplazar cada píxel blanco de la imagen original por una réplica del elemento estructurante.




Figura 13. Dilatación de una imagen.

Añade todos los puntos del fondo que tocan el borde de un objeto, la dilatación es extensiva. Rellena entrantes en los que no quepa el EE (pequeños agujeros y bahías).

— **Erosión:**

La salida de la erosión es el conjunto de puntos barridos por el centro del EE mientras se cumpla que todos los puntos de entrada estaban contenidos en el EE. Elimina grupos de píxeles donde el EE no cabe.




Figura 14. Erosión de una imagen.

La erosión es antiextensiva luego reduce el tamaño del objeto. Elimina elementos en los que no quepa el EE (pequeñas islas y protuberancias). No es exactamente la inversa de la dilatación. Una de las aplicaciones más típicas de la erosión es la eliminación de detalles irrelevantes (desde el punto de vista del tamaño).

— **Aperturas:**

Es la composición de un operador de erosión y otro de dilatación con el mismo elemento estructurante.




Figura 15. Apertura de una imagen.

Se obtiene desplazando el EE por el interior del conjunto y eliminando las zonas por las que este no pueda "pasar".

Es un operador antiextensivo e idempotente. Sus principales propiedades son el alisado de contornos (redondear las esquinas donde no quepa el EE). Elimina las protuberancias donde no quepa el EE y separa objetos en puntos estrechos.

— **Cierres:**

Es la composición de un operador de dilatación seguido de otro de erosión con el mismo elemento estructurante.




Figura 16. Cierre de una imagen.

Tiene una interpretación geométrica similar al caso del operador apertura con la diferencia de que ahora los desplazamientos por el conjunto de datos se producen por fuera de la frontera de los mismos.

Es un operador extensivo e idempotente. Tiende a alisar porciones del contorno, fusiona estrechas grietas, y rellena vacíos en el contorno. También rellena agujeros pequeños y elimina los entrantes pequeños. Conecta objetos vecinos.

— **Tophat/Bottomhat:**

Es un filtro morfológico que resalta objetos de color contrario al fondo. Se define como:

$h = f - f \circ b$ , donde  $f$  es la imagen y  $b$  el elemento estructural.

Esta transformación es útil para resaltar detalles claros en la presencia de sombras, o viceversa ( $h = f \circ b - f$ ) para objetos oscuros sobre fondo blanco.




Figura 17. Ejemplo de filtro Tophat.

### 3.3.6 Tratamiento morfológico a las bandas calculadas.

En todas las operaciones con las bandas se han utilizado dos elementos estructurales. Uno rectangular y otro en forma de rombo, ya que casi todas las construcciones tienen una forma cuadrada y es la forma geométrica más ajustada a lo que buscamos. El tamaño en ambos casos del elemento estructural es de 15 píxeles de lado.

Partimos de las siguientes bandas extraídas anteriormente:



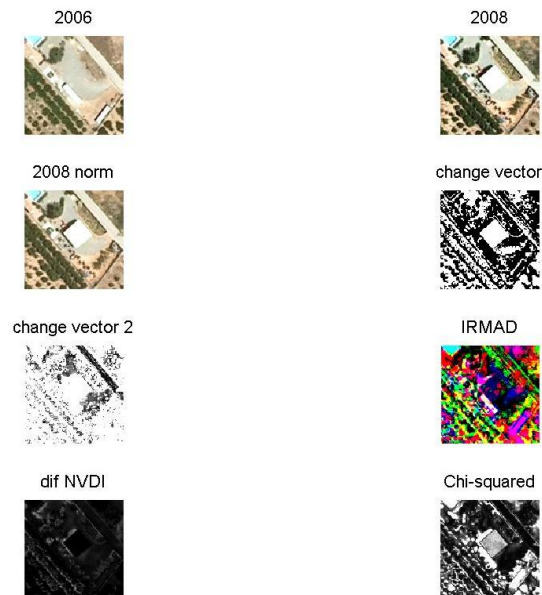


Ilustración 18 Bandas extraídas para los cálculos.

Para la primera clasificación, cogemos las bandas que anteriormente en la figura 18 se denominan 2008 normalizado y IRMAD. De la normalización de 2008 cogemos la banda del Rojo (banda 1) y de las transformadas MAD cogemos la banda 4 que corresponde al infrarrojo (banda 4) y es donde mejor se detecta el cambio:

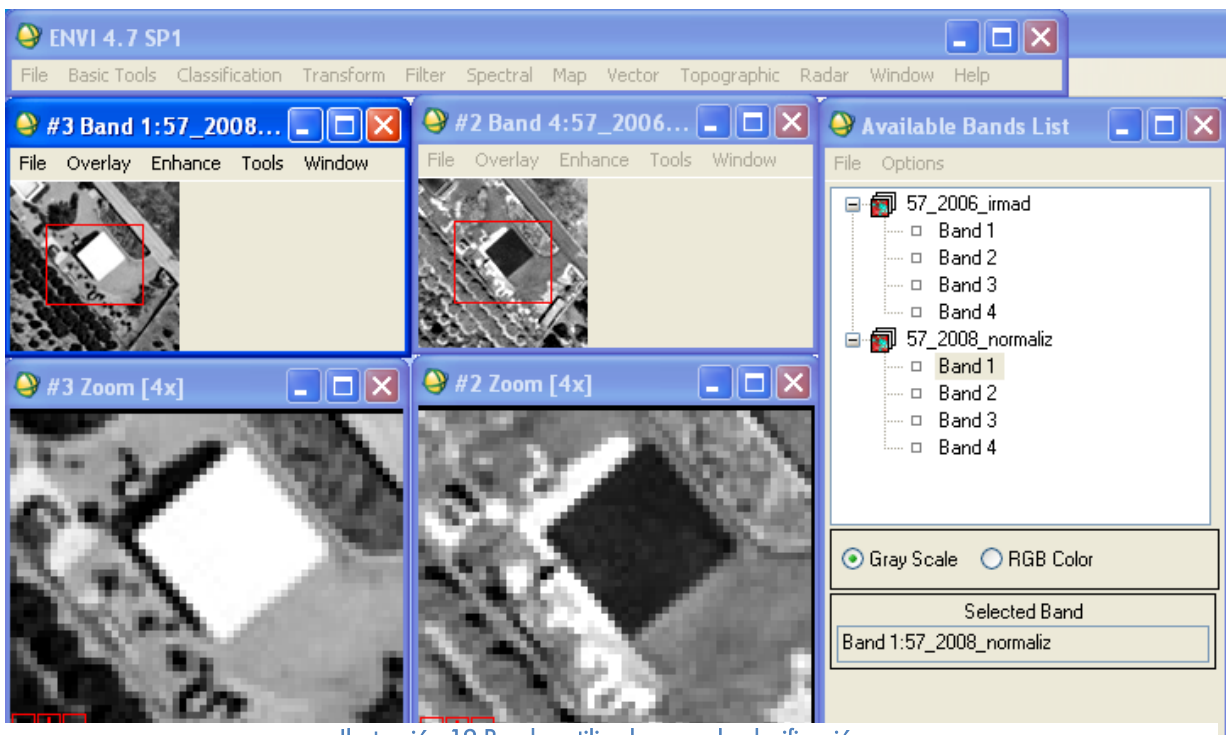


Ilustración 19 Bandas utilizadas para la clasificación.

Para cada una de ellas realizamos las siguientes operaciones morfológicas:

- Erosión
- Apertura
- Cierre

Se muestra en la figura 20 estas operaciones para la banda 1 de la imagen 2008 normalizada:




Figura 20 Operaciones morfológicas a la banda 1 de la imagen 2008 normalizada.

Se han realizado las mismas a la banda extraída de la transformada MAD en el infrarojo:




Figura 21 Operaciones morfológicas en la banda 4 de la transformada MAD.

En todas estas operaciones morfológicas el elemento estructural era un cuadrado y un rombo de 15 píxeles de lado.

Se han utilizado estos datos de entrada para el clasificador no supervisado k-means. A continuación explicamos en que se basa y los resultados obtenidos.

### 3.3.7 Clasificador k-means:

El algoritmo K-means, creado por MacQueen en 1967 es el algoritmo de clustering más conocido y utilizado ya que es de muy simple aplicación y eficaz. Sigue un procedimiento simple de clasificación de un conjunto de objetos en un determinado número K de clústeres, K determinado a priori. El nombre de K-means viene porque representa cada uno de los clústeres por la media (o media ponderada) de sus puntos, es decir, por su

centroide. La representación mediante centroides tiene la ventaja de que tiene un significado gráfico y estadístico inmediato. Cada clúster por tanto es caracterizado por su centro o centroide (ver figura 9) que se encuentra en el centro o el medio de los elementos que componen el clúster. Kmeans es traducido como K-medias, o un conjunto de objetos:

$D_n = (x_1, x_2, \dots, x_n)$ , para todo el  $i$ ,  $x_i$  reales y  $k, \dots, 1$ , los centros de los  $K$  clúster.

El algoritmo del K-means se realiza en 4 etapas:

- **Etapa 1:** Elegir aleatoriamente  $K$  objetos que forman así los  $K$  clústeres iniciales. Para cada clúster  $k$ , el valor inicial del centro es  $= x_i$ , con los  $x_i$  únicos objetos de  $D_n$  pertenecientes al clúster.
- **Etapa 2:** Reasigna los objetos del clúster. Para cada objeto  $x$ , el prototipo que se le asigna es el que es más próximo al objeto, según una medida de distancia, (habitualmente la medida euclidiana).
- **Etapa 3:** Una vez que todos los objetos son colocados, recalculan los centros de  $K$  clúster. (los baricentros).
- **Etapa 4:** Repetir las etapas 2 y 3 hasta que no se hagan más reasignaciones. Aunque el algoritmo termina siempre, no se garantiza el obtener la solución óptima. En efecto, el algoritmo es muy sensible a la elección aleatoria de los  $K$  centros iniciales. Esta es la razón por la que, se utiliza el algoritmo del K-means numerosas veces sobre un mismo conjunto de datos para intentar minimizar este efecto, sabiendo que a centros iniciales lo más espaciados posibles dan mejores resultados.

Entre los inconvenientes de este clasificador tenemos

- Uno de los inconvenientes principales del K-means, además del hecho de que sea necesario realizar en sucesivas ocasiones el algoritmo para así tener el resultado más óptimo posible, es la necesidad de inicializar el número de prototipos al principio de la ejecución. Esto perjudica la eficacia del algoritmo ya que en la práctica, no se conoce a priori el número de clúster final. Este defecto le perjudicaría al compararlo con otros algoritmos, ya que en muchos la inicialización del número de clústeres no es necesaria.
- k-means es susceptible a valores extremos porque distorsionan la distribución de los datos.

Aplicando este clasificador a las bandas calculadas anteriormente (Figura 20 y Figura 21) y con diferentes parámetros del mismo, se obtiene el siguiente resultado (figura 22):

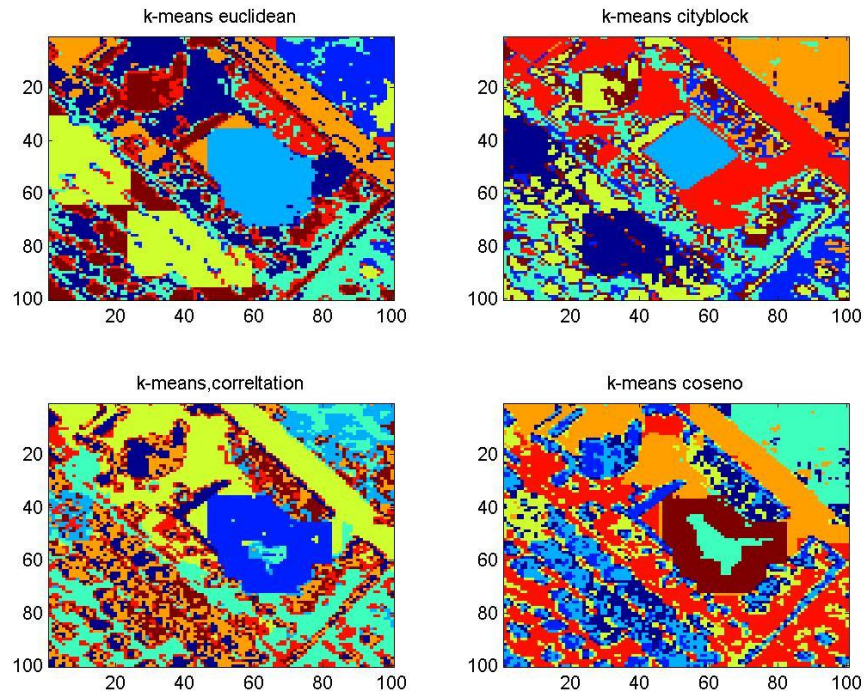


Figura 22 Resultados clasificador k-means.

Se ha configurado el algoritmo con 1000 iteraciones. Se han etiquetado un total de ocho clases. Este algoritmo crea las diferentes clases basadas en la distancia de todos los componentes de una al centroide o punto de gravedad. Esta distancia se puede calcular de cuatro formas diferentes. Estas cuatro maneras diferentes de crear las clases muestran resultados diferentes. Las distancias utilizadas como parámetro del clasificador son las siguientes:

- k-means euclidean.- Se basa en el cálculo de la distancia euclídea de los componentes respecto al centroide.
- k-means cityblock.- Se basa en la media del sumatorio de todas las distancias en valor absoluto.
- k-means coseno.- Se basa en la media de la resta de uno menos el coseno del ángulo que forma el componente con el centroide.
- k-means correlation.- Se basa en la media de las distancias de los componentes al centroide normalizados según la desviación típica.

Vemos que el que mejor resultados ofrece es el de 'cityblock'. Se aprecia que la clase 3 etiquetada de color azul claro es la nueva construcción.

Una vez que tenemos ya calculada una clase que contiene este cambio, es decir, la clase anterior refleja la nueva construcción sobre el territorio, tenemos que saber diferenciarla del resto de clases (de las ocho calculadas, una se corresponde con lo buscado y las otras siete no).

Para discriminar esta clase del resto aplicamos un algoritmo basado en la compacidad de las mismas, ya que una nueva construcción normalmente sigue una forma geométrica compacta, esta clase tendrá todos sus componentes juntos y no disgregados por la imagen. Calculamos la compacidad de cada una de ellas buscando la posición que ocupan los píxeles en la imagen clasificada, se calcula la desviación típica de las coordenadas X e Y, y la raíz de la suma cuadrática de ambas muestra la compacidad de la clase:

. Siendo  $std(X)$  desviación típica de las coordenadas X de los píxeles de una clase y  $std(Y)$  lo mismo para la coordenada Y.

Los resultados son:

clase1	31.8794
clase2	40.2381
clase3	10.5816
clase4	40.0385
clase5	38.5057
clase6	24.7060
clase7	34.1711
clase8	40.0663

Figura 23 Compactación de las clases.

Para la clase dos el valor es 10,5, siendo con diferencia, el mas compacto de todas. Vemos en la figura 24 como se corresponde con la situación de la nueva construcción en el territorio.

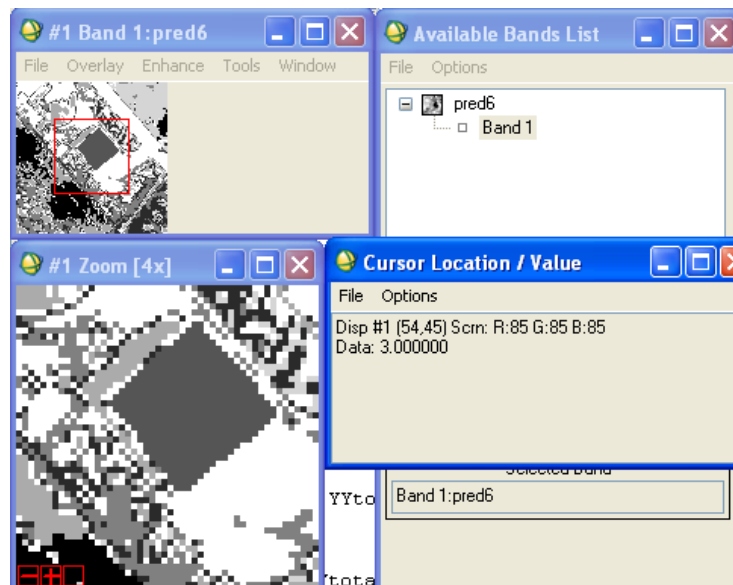


Figura 24 Imagen clasificada con kmeans, cursor en clase 2

Vamos a realizar los mismos pasos anteriores pero utilizando otras bandas extraídas anteriormente para comprobar si también llegan a la detección de las nuevas construcciones en el territorio.

Para ello utilizamos el vector de cambios espectral y la banda chi cuadrado. En la figura 25 vemos el vector de cambios y las operaciones morfológicas calculadas:

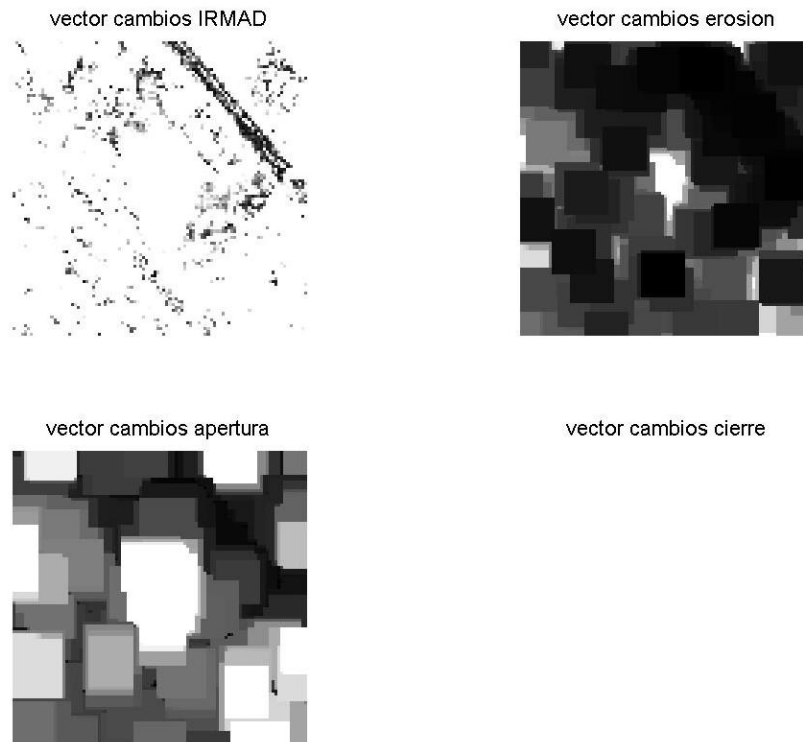


Ilustración 25 Vector de cambios y operaciones morfológicas.

Vemos en la figura 26 la banda chi cuadrado y sus operaciones morfológicas:




Figura 26 Chi cuadrado y operaciones morfológicas.

Aplicamos el mismo clasificador con los mismos parámetros a las bandas de entrada:

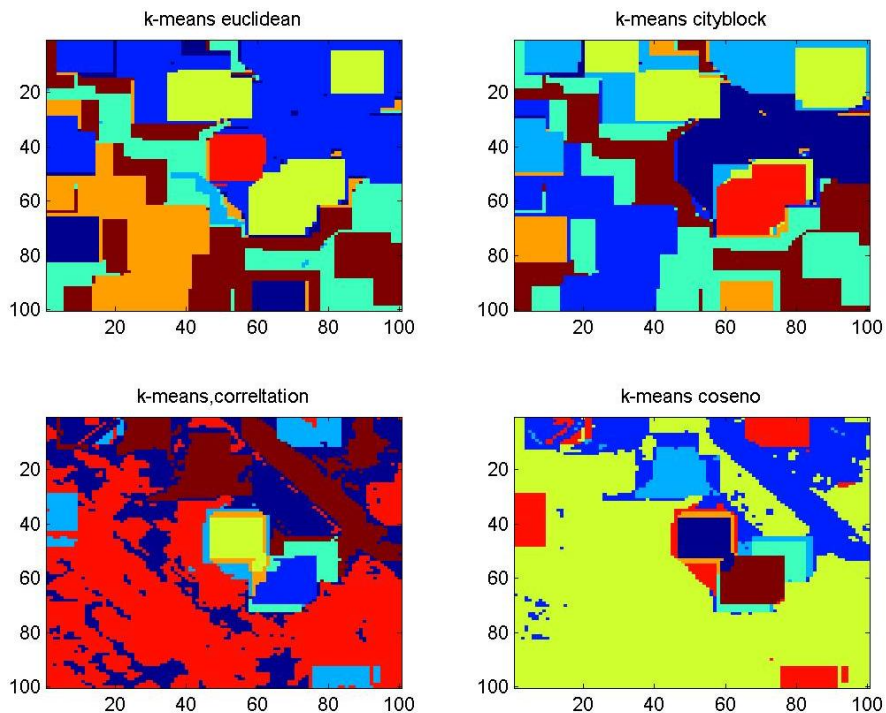


Ilustración 27 Clasificación kmeans sobre las bandas extraídas.

Con estas bandas de entrada se puede apreciar en la figura un cambio en la clase amarilla de la clasificación 'k-means correlation' pero que no llega a ser tan precisa como la anterior, que ha sido calculada a partir de otras bandas (2008 normalizado y transformada MAD).

#### 4. Conclusiones.

Porcentajes de aciertos/fallos sobre la muestra de datos:

Se han procesado un total de 122 pares de imágenes de diferentes fechas que contienen en cada una de ellas una nueva construcción. Todas se adjuntan en el Cd de entrega de la tesina.

Los cálculos realizados arrojan las siguientes estadísticas (ver tabla 10)

Imágenes	Aciertos	Fallos	Porcentaje
122	91	31	74.5%

Tabla 10 Resultados.

Causas que empeoran la calidad de los resultados:

- La gran cantidad de cambios que hay entre ambas imágenes y que no son solo nuevas construcciones, como por ejemplo las sombras, la vegetación, el diferente color de las tomas (aunque se han normalizado sigue habiendo diferencias), elementos nuevo que no son construcciones como vehículos, piscinas, balsas, etc.
- La variedad de formas y tamaños de las nuevas construcciones, si se buscara en las

imágenes un elemento invariable con forma, tamaño y textura conocida la detección sería más fácil.

Como posibles mejoras del algoritmo caben las siguientes posibilidades:

- Utilizar nuevas fuentes cartográficas para la detección de nuevas construcciones, como por ejemplo LIDAR. Actualmente solo se dispone de un vuelo LIDAR de la Comunidad Valenciana, no se puede utilizar como serie histórica pero sí como cartografía de apoyo o de verificación.
- Utilizar otras imágenes con diferente información espectral. Se pueden utilizar imágenes de satélite en otras bandas para incluirlas en los clasificadores, la desventaja es que no tiene todavía la resolución del a ortofoto, que es de 50cm.
- Explorar nuevas transformaciones morfológicas para intentar asilar los cambios entre las imágenes de la serie histórica.
- Probar nuevos clasificadores, en este trabajo se ha utilizado solo clasificadores post-proceso, pero puede explorarse la posibilidad de utilizar SVN, clasificadores pre-proceso, etc.



## 5. Bibliografía.

- [1] : Erasmi, S., Cyffka, B. and M. Kappas., 2010. AUTOMATIC CHANGE DETECTION IN URBAN AREAS UNDER A SCALE-SPACE, OBJECT-ORIENTED CLASSIFICATION FRAMEWORK. In (eds.): *Göttinger Geographische Abhandlungen*, 113, pp. 1-9.
- [2] Lu, D., Mausel, P., Brondizio, E. and Moran, E., 2004. Change detection techniques. In: *International Journal of Remote Sensing*, Vol.25, no.12, pp. 2365–2407.
- [3] Sui, H., Zhou, Q., Gong, J. and Ma, G., 2008. Processing of multi-temporal data and change detection. In: Li, Z. L., Chen, J., Baltasvias, E., eds. *Advances in Photogrammetry, Remote Sensing and Spatial Information Sciences: 2008 ISPRS Congress Book*, Taylor & Francis, Nottingham, pp. 227—247.
- [4] Champion, N., Boldo, D., Pierrot-Deseilligny, M., and Stamon G., 2009b. 2D building change detection from high resolution satellite imagery: A two-step hierarchical method based on 3D invariant primitives. *Pattern Recognition Letters*, In Press, Corrected Proof, Available online 22 October 2009.
- [5] Bouziani, M., Goita, K. and 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*, Vol. 65, Issue 1, pp. 143-153
- [6] Jensen, R.J., 2005. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 3rd ed., Pearson Education, USA, pp.470, 478-480
- [7] Donnay, J. P., Barnsley, M. and Longley, P., 2001. *Remote Sensing and Urban Analysis*, Taylor & Francis, London, pp.3-18.
- [8] Champion, N., Boldo, D., Pierrot-Deseilligny, M., and Stamon G., 2009b. 2D building change detection from high resolution satellite imagery: A two-step hierarchical method based on 3D invariant primitives. *Pattern Recognition Letters*, In Press, Corrected Proof, Available online 22 October 2009
- [9] Bouziani, M., Goita, K. and 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*, Vol. 65, Issue 1, pp. 143-153.
- [10] Blaschke, T., 2004. Towards a framework for change detection based on image objects. In: Erasmi, S., Cyffka, B. and M. Kappas (eds.): *Göttinger Geographische Abhandlungen*, 113, pp. 1-9.
- [11] Aasbjerg Nielsen, Allan, 2007. The Regularized Iteratively Reweighted MAD Method for Change Detection in Multi- and Hyperspectral Data. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, VOL. 16, NO. 2, FEBRUARY 2007.
- [12] Morton J. Canty Allan A. Nielsen. 2008. Automatic radiometric normalization of multitemporal satellite imagery with the iteratively re-weighted MAD transformation. *Remote Sensing of Environment* 112 (2008) 1025–1036
- [13] Cristina García Cambronero, Irene Gómez Moreno, 2008, “ALGORITMOS DE APRENDIZAJE: KNN & KMEANS”
- [14] Morfología de imágenes.  
[http://www.tsc.uc3m.es/imagen/Curso\\_ProcesadoMorfologico/Contenido/Operaciones/OperacionesMorfologicas.html](http://www.tsc.uc3m.es/imagen/Curso_ProcesadoMorfologico/Contenido/Operaciones/OperacionesMorfologicas.html)
- [15] Camps Valle, Gustavo; Soria Olivas, Emilio; Frances Villora, Jose Vicente; 2004 “Tratamiento digital de señales. Ejercicios y problemas resueltos”. Pearson Educacion.

## 6. Anexos.

### 6.1 Anexo 1.- Código fuente de ArcGis.

- Una vez delineado un punto sobre cada nueva construcción se crea un buffer de 50 metros para cada uno:

```
# -----
# script_01.py
# Created on: 2012-09-17 12:18:03.00000
# (generated by ArcGIS/ModelBuilder)
# Usage: script_01 <Valor>
# Description:
# -----
# Import arcpy module
import arcpy
# Load required toolboxes
arcpy.ImportToolbox("Model Functions")
# Script arguments
Valor = arcpy.GetParameterAsText(0)
if Valor == '#': or not Valor:
    Valor = "122" # provide a default value if unspecified
# Local variables:
consil_construcciones_2006_exacto = "consil_construcciones_2006_exacto"
l_consil_construcciones_2006_exacto_FID = "l_consil_construcciones_2006_exacto_FID"
v_Valor__shp =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2008\\buffer_02\\%Valor%.shp"
# Process: Iterar selección de entidades
arcpy.IterateFeatureSelection_mb(consil_construcciones_2008_exacto, "FID #", "false")
# Process: Zona de influencia
arcpy.Buffer_analysis(l_consil_construcciones_2008_exacto_FID, v_Valor__shp, "50 Meters", "FULL",
"ROUND", "NONE", "")
```

- La salida es un círculo en formato shape vectorial, se transforma en cuadrado de 50 metros de lado:

```
# -----
# script_02.py
# Created on: 2012-09-17 12:18:20.00000
# (generated by ArcGIS/ModelBuilder)
# Description:
# -----
# Import arcpy module
import arcpy
# Load required toolboxes
arcpy.ImportToolbox("Model Functions")
# Local variables:
v_Valor__shp__2_ =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2006\\buffers\\%Valor%.shp"
v_Valor__shp__3_ =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2006\\buffer_02\\%Valor%.shp"
v_Valor__shp =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2006\\envelope_06\\%Valor%.shp"
# Process: Geometría mínima de delimitación
arcpy.MinimumBoundingGeometry_management(v_Valor__shp__3_, v_Valor__shp, "ENVELOPE", "NONE", "",
"NO_MBG_FIELDS")
# Process: Para
```

```
arcpy.IterateCount_mb("0", "122", "1")
```

- Se recorta cada una de las ortofotos de 2006 y 2008 a partir del cuadrado generado:

```
# -----
# script_03.py
# Created on: 2012-09-17 12:18:34.00000
# (generated by ArcGIS/ModelBuilder)
# Description:
# -----
# Import arcpy module
import arcpy
# Check out any necessary licenses
arcpy.CheckOutExtension("spatial")
# Load required toolboxes
arcpy.ImportToolbox("Model Functions")
# Set Geoprocessing environments
arcpy.env.compression = "NONE"
arcpy.env.rasterStatistics = "NONE"
arcpy.env.tileSize = "128 128"
arcpy.env.pyramid = "NONE"
arcpy.env.cellSize = "MAXOF"
arcpy.env.mask = ""
# Local variables:
orto_2008_tif = "C:\\Users\\Documents\\Tesina_master\\Cartografia\\orto_2008\\orto_2008.tif"
v_Valor__shp =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2008\\buffer_02\\%%Valor%.shp" _Valor__shp
= "C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2008\\buffer_02\\%%Valor%.shp" v0__shp =
"C:\\Users\\pomelo\\Documents\\Tesina_master\\Cartografia\\consil_2002\\envelope_02\\0.shp"
orto_2006_tif = "C:\\Users\\pomelo\\Documents\\Tesina_master\\Cartografia\\orto_2006\\orto_2006.tif"
v_Valor__shp__2_ =
"C:\\Users\\Documents\\Tesina_master\\Cartografia\\consil_2006\\envelope_02\\%%Valor%.shp"
v_Valor__tif = "C:\\Users\\Documents\\Tesina_master\\Cartografia\\extract_2006\\100m\\%%Valor%.tif"
# Process: Para
arcpy.IterateCount_mb("0", "122", "1")
# Process: Extraer por máscara
arcpy.gp.ExtractByMask_sa(orto_2006_tif, v_Valor__shp__2_, v_Valor__tif)
```

## 6.2 Anexo 2.- Código fuente de ENVI.

Esta rutina lee los datos de entrada y calcula las 16 bandas a partir de las cuales se basa el trabajo de detección:

```
pro lee_tif_orto_alf
```

```
path2008='C:\temp\CIR_2008\recorte_50m\'
path2008b='C:\temp\RGB_2008\recorte_50m\'
path2006='C:\temp\CIR_2006\recorte_50m\'
path2006b='C:\temp\RGB_2006\recorte_50m\'
pathout='C:\temp\CIR_2006_2008\'
```

```
num=141
nam=indgen(num)
ch=strcompress(string(nam),/remove_all)
```

```
data_typ=1
col=100
row=100
im=fltarr(col,row,16)
for i=0,num-1 do begin
fout=pathout+ch(i)
```

```

fout1=pathout+ch(i)+'_2006'
fout2=pathout+ch(i)+'_2008'
fim=path2006+ch(i)+'.tif'
fimb=path2006b+ch(i)+'.tif'

imagen=read_tiff(fimb)
imagen_cir=read_tiff(fim)
B=imagen(2,*,*)
G=imagen(1,*,*)
R=imagen(0,*,*)
IR=imagen_cir(0,*,*)
up=(IR*1.0-R) & down=IR*1.0+R & wh=where(down > 0)
ndvi=fltarr(col,row) & ndvi(wh)=up(wh)/down(wh) > 0

im(*,*,0)=B & im(*,*,1)=G & im(*,*,2)=R & im(*,*,3)=IR & im(*,*,4)=ndvi
fim=path2008+ch(i)+'.tif'
fimb=path2008b+ch(i)+'.tif'
imagen=read_tiff(fimb)
imagen_cir=read_tiff(fim)
B=imagen(2,*,*)
G=imagen(1,*,*)
R=imagen(0,*,*)
IR=imagen_cir(0,*,*)
up=(IR*1.0-R) & down=IR*1.0+R & wh=where(down > 0)
ndvi=fltarr(col,row) & ndvi(wh)=up(wh)/down(wh) > 0

im(*,*,5)=B & im(*,*,6)=G & im(*,*,7)=R & im(*,*,8)=IR & im(*,*,9)=ndvi

im(*,*,10)=im(*,*,5)-im(*,*,0)
im(*,*,11)=im(*,*,6)-im(*,*,1)
im(*,*,12)=im(*,*,7)-im(*,*,2)
im(*,*,13)=im(*,*,8)-im(*,*,3)
im(*,*,14)=im(*,*,9)-im(*,*,4)
im(*,*,15)=sqrt(im(*,*,12)^2+im(*,*,13)^2+im(*,*,14)^2)

writefile,fout,im
writefile,fout1,im(*,*,0:3)
writefile,fout2,im(*,*,5:8)
file_typ='bsq'
byte_ord=0
names4=['BLUE','GREEN','RED','IR']

names16=['2006_GREEN','2006_BLUE','2006_RED','2006_IR','2006_NDVI',
'2008_GREEN','2008_BLUE','2008_RED','2008_IR','2008_NDVI',
'dif_GREEN','dif_BLUE','dif_RED','dif_IR','dif_NDVI','change vector']

writehdr,fout+'.hdr',col,row,4,file_typ,byte_ord,16,names16;,wavel,mapinfo=mapinfo,xystart=xystart
writehdr,fout1+'.hdr',col,row,4,file_typ,byte_ord,4,names4;,wavel,mapinfo=mapinfo,xystart=xystart
writehdr,fout2+'.hdr',col,row,4,file_typ,byte_ord,4,names4;,wavel,mapinfo=mapinfo,xystart=xystart

tvsc1,im(*,*,0)
endfor

end

```

### 6.3 Anexo 3.- Código fuente Matlab.

- Se empieza la ejecución de todo en la rutina tesina\_total.m:

```

%Detección de nuevas construcciones en diseminadov a partir de ortofotos
%del ICV
%Alfonso Moya Fuero
%Master de teledetección 2011/12
%Tutor Javier Garcia Haro
clear all;
close all;
%Path de las funciones auxiliares
addpath(genpath('C:\temp\programas\imm4695NEW\'))
addpath('C:\temp\programas\');

```

```

addpath('C:\temp')

%Path de los datos de entrada
path1='C:\temp\CIR_2008\recorte_50m\';
path2='C:\temp\CIR_2006\recorte_50m\';
path='C:\temp\CIR_2006_2008\';

%Para aplicar en caso de todas las imágenes
num=141;
ii=(0:num-1)';
cadena=int2str(ii);
%%%%% celda=cellstr(cadena); ch=char(celda)

%Bucle para iterar sobre las imágenes en caso de calcular todas
for i=1:141
    fname1=[path, strtrim(cadena(i,:)), '_2006']; % original 2006
    fname2=[path, strtrim(cadena(i,:)), '_2008']; % original 2008
    fname_dif=[fname2, '_dif_2006']; %diferencia imagenes normalizada
    fname_dif2=[fname2, '_dif_2006_2']; %residuos del vector de cambios
    fname2_normaliz=[fname2, '_normaliz']; %imagen 2008 normalizada
    fout=[fname1, '_mad']; %
    fout_irmad=[fname1, '_irmad']; % transformada MAD
    fout_irmad_chi2=[fname1, '_irmad_chi2']; % chi cuadrado
    [X,x,y,info]=enviread_javier1(fname1);
    [Yorig,x,y,info]=enviread_javier1(fname2);
    figure(2);
    subplot(2,2,1), imshow(X(:,:, [3 2 1])/200, 'InitialMagnification', 300), title('2006');
    subplot(2,2,2), imshow(Yorig(:,:, [3 2 1])/200, 'InitialMagnification', 300), title('2008');

    [mads, rho, v1, v2, s11, s22, s12, w, chi2] =irmadenvi_mio(fname1, fname2);
    j=enviwritel_simple(real(mads), fout_irmad);
    j=enviwritel_simple(real(chi2), fout_irmad_chi2);

    % A3 --> (row,col,ban) a diferencia ENVI (col,row,ban)
    Xorig=X;
    [nrows, ncols, nvar1]=size(X) %ncols=info.samples; nrows=info.lines; nvar1=info.bands;

    X=reshape(X, nrows*ncols, nvar1);
    Y=reshape(Yorig, nrows*ncols, nvar1);
    [chi2,x,y,info2]=enviread_javier1(fout_irmad_chi2); % A3 --> (row,col,ban) a diferencia ENVI
    (col,row,ban)
    chi2=reshape(chi2, nrows*ncols, 1);
    wh=find(chi2 < 2);
    figure(5); plot(X(wh,1), Y(wh,1), 'k. ');
    %Find a value that exceeds 95% of the samples from a chi-square distribution
    %Ejemplo: 10 degrees of freedom. x = chi2inv(0.95,10) Resultado x =18.3070
    p_nocambio=0.95
    %p_nocambio=0.90
    th = chi2inv(1-p_nocambio, nvar1);
    wh=find(chi2 < th);
    for i=1:nvar1,
        x=X(wh,i); y=Y(wh,i);
        figure(i+4); plot(x,y, 'k. ');
        [a,b,sa,sb,r,p] = rma(y,x); %%% funcion que calcula la matriz de correlacion
        y1=a+y*b;
        figure(i+5); plot(x,y1, 'k. ');
        xx=[0 max(x)]; hold on; plot(xx,xx, 'r--');
        Y(:,i)=a+Y(:,i)*b;
    end
    Y=reshape(Y, nrows, ncols, nvar1); %%% Imagen 2008 normalizada

    %close all

    [MAD,x,y,info]=enviread_javier1(fout_irmad); % A3 --> (row,col,ban) a diferencia ENVI
    (col,row,ban)
    dif=Xorig-Y;
    change_vector=sum(dif.*dif,3); % Vector de diferencias normalizado

    j=enviwritel_simple(Y, fname2_normaliz); % Escritura a ENVI 2008 normalizado
    j=enviwritel_simple(change_vector, fname_dif2); % change vector (sumatorio de dif^2)
    j=enviwritel_simple(Y-Xorig, fname_dif); % dif o residuo (multiespectral)

end;
%%%%%Ya se han calculado los datos de entrada, vamos a empezar los
%%%%% analisis morfologicos y clasificaciones
for i=58:58
    a=[path, strtrim(cadena(i,:)), '_2006'];
    [aa,x,y,infoa]=enviread_javier1(a);
    b=[path, strtrim(cadena(i,:)), '_2008'];
    [bb,x,y,infob]=enviread_javier1(b);

```

```

c=[path,strtrim(cadena(i,:)),'_2008_dif_2006'];
[cc,x,y,infoc]=enviread_javier1(c);
d=[path,strtrim(cadena(i,:)),'_2008_normaliz'];
[dd,x,y,infod]=enviread_javier1(d);
e=[path,strtrim(cadena(i,:)),'_2006_irmad'];
[ee,x,y,infoe]=enviread_javier1(e);
f=[path,strtrim(cadena(i,:)),'_2006_irmad_chi2'];
[ff,x,y,infof]=enviread_javier1(f);
imagenout=[path,strtrim(cadena(i,:)),'_01.jpg'];
figure(10);
subplot(2,2,1),imshow(aa(:,:, [3 2 1])/200,'InitialMagnification',300),title('2006');
subplot(2,2,2),imshow(bb(:,:, [3 2 1])/200,'InitialMagnification',300),title('2008');
subplot(3,2,3),imshow(cc(:,:, [3 2 1])/200,'InitialMagnification',300),title('diferencia');
subplot(3,2,4),imshow(dd(:,:, [3 2 1])/200,'InitialMagnification',300),title('2008
normalizado');
subplot(3,2,5),imshow(ee(:,:,1:3)/2,'InitialMagnification',300),title('IRMAD');
subplot(3,2,6),imshow(ff,gray(256),'InitialMagnification',300),title('IRMAD chi2');
print -djpeg imagenout;

end;

```

- Cálculo de las clases con kmeans:

```

%Deteccion de nuevas construcciones en diseminadov a partir de ortofotos
%del ICV
%Alfonso Moya Fuero
%Master de teledetección 2011/12
%Tutor Javier Garcia Haro
clear all;
close all;
%Path de las funciones auxiliares

path='C:\temp\'; % ALFONSO
%path='C:\temp\programas'; % ALFONSO

addpath(genpath([path,'programas\imm4695NEW\']))
addpath([path,'programas']);

%Path de los datos de entrada
path1=[path,'\CIR_2008\recorte_50m\'];
path2=[path,'\CIR_2006\recorte_50m\'];
path_im=[path,'\imagenes\'];
path_salida=[path,'\resultados\01\'];
%Para aplicar en caso de todas las imagenes
num=141;
ii=(0:num-1)';
cadena=int2str(ii); %%% celda=cellstr(cadena); ch=char(celda)

%Bucle para iterar sobre las imagenes en caso de calcular todas
% casos 0,110novabien,116,128, 139 (en realidad, hay que añadir 1)
for i=58:58
a1=[path_im,strtrim(cadena(i,:)),'_2006']; % original 2006
a2=[path_im,strtrim(cadena(i,:)),'_2008']; % original 2008
a3=[path_im,strtrim(cadena(i,:)),'_2008_dif_2006']; % resta multiespectral (norm2006-norm2008)
a4=[path_im,strtrim(cadena(i,:)),'_2008_normaliz']; % normalizadaIRMAD 2006
a5=[path_im,strtrim(cadena(i,:)),'_2008_dif_2006_2']; % change vector (sumatorio de dif ^ 2)
a6=[path_im,strtrim(cadena(i,:)),'_2006_IRMAD']; % normalizadaIRMAD 2008
a7=[path_im,strtrim(cadena(i,:)),'_dif_NVDI']; % dif_NDVI (sin normalizar) OJO, calcular con matlab
a8=[path_im,strtrim(cadena(i,:)),'_2006_irmad_chi2']; % irmad_chi2

fname1=[path_salida,strtrim(cadena(i,:))];

[b1,x1,y1,info1]=enviread_javier1(a1);
[b2,x2,y2,info2]=enviread_javier1(a2);
[b3,x3,y3,info3]=enviread_javier1(a3);
[b4,x4,y4,info4]=enviread_javier1(a4);
[b5,x5,y5,info5]=enviread_javier1(a5);
[b6,x6,y6,info6]=enviread_javier1(a6);
[b7,x7,y7,info7]=enviread_javier1(a7);
[b8,x8,y8,info8]=enviread_javier1(a8);

[nrows, ncols, nvar1]=size(b1)
se = strel('square',15); % elemento estructural
% se1 = strel('square',11) % 11-by-11 square
% se2 = strel('line',10,45) % line, length 10, angle 45 degrees

```

```

% se3 = strel('disk',15) % disk, radius 15
% se4 = strel('ball',15,5) % ball, radius 15, height 5
banda=3;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%% el mejor el pred2, vamos a probar diferentes kmeans a partir de esos
%%% datos, utilizando diferentes clusterings
l = b5;
I1 = imerode(l,se); X1 = reshape(I1,ncols*nrows,1);
I2 = imopen(l,se); X2 = reshape(I2,ncols*nrows,1);
I3 = imclose(l,se); X3 = reshape(I3,ncols*nrows,1);
% Pasamos la imagen a matriz:
XX = reshape(b4(:,1:3),nrows*ncols,3); % solo informacion espectral
XXtotal = [XX,X1,X2,X3]; % informacion espacio-espectral
figure(1),
subplot(2,2,1), imshow(I/200), title('vector cambios IRMAD');
subplot(2,2,2), imshow(I1/200), title('vector cambios erosion');
subplot(2,2,3), imshow(I2/200), title('vector cambios apertura');
subplot(2,2,4), imshow(I3/200), title('vector cambios cierre');
imagenout = [fname1,'figura_03_1.jpg'];
print (figure(1),'-djpeg', imagenout);
J = b8;
J1 = imerode(l,se); X1 = reshape(J1,ncols*nrows,1);
J2 = imopen(l,se); X2 = reshape(J2,ncols*nrows,1);
J3 = imclose(l,se); X3 = reshape(J3,ncols*nrows,1);
% Pasamos la imagen a matriz:
YY = reshape(b6(:,1:3),nrows*ncols,3); % solo informacion espectral
YYtotal = [XX,X1,X2,X3]; % informacion espacio-espectral
figure(2),
subplot(2,2,1), imshow(J), title('chi 2');
subplot(2,2,2), imshow(J1/200), title('chi 2 erosion');
subplot(2,2,3), imshow(J2/200), title('chi 2 apertura');
subplot(2,2,4), imshow(J3/200), title('chi 2 cierre');
imagenout = [fname1,'figura_03_2.jpg'];
print (figure(2),'-djpeg', imagenout);
XY=[XX,YY];
XYtotal=[XXtotal,YYtotal];

Pred5 = kmeans(XYtotal,8,'Maxiter',1000);
Pred6 = kmeans(XYtotal,8,'distance','cityblock','Maxiter',1000);
Pred7 = kmeans(XYtotal,8,'distance','correlation','Maxiter',1000);
Pred8 = kmeans(XYtotal,8,'distance','cosine','Maxiter',1000);

j=enviwrite1_simple(reshape(Pred6,100,100),'C:\temp\pred6');
figure(3),
subplot(2,2,1), imagesc(reshape(Pred5,[nrows,ncols])),title('k-means euclidean'); % de vectores a imagen
subplot(2,2,2), imagesc(reshape(Pred6,[nrows,ncols])),title('k-means cityblock');
subplot(2,2,3), imagesc(reshape(Pred7,[nrows,ncols])),title('k-means correlation'); % de vectores a imagen
subplot(2,2,4), imagesc(reshape(Pred8(1:10000,1),[nrows,ncols])),title('k-means coseno');
imagenout = [fname1,'figura_03_3.jpg'];
print (figure(3),'-djpeg', imagenout);

[r1,s1]=find(reshape(Pred6,100,100)==1);
[r2,s2]=find(reshape(Pred6,100,100)==2);
[r3,s3]=find(reshape(Pred6,100,100)==3);
[r4,s4]=find(reshape(Pred6,100,100)==4);
[r5,s5]=find(reshape(Pred6,100,100)==5);
[r6,s6]=find(reshape(Pred6,100,100)==6);
[r7,s7]=find(reshape(Pred6,100,100)==7);
[r8,s8]=find(reshape(Pred6,100,100)==8);
clase1=sqrt(std(r1)^2+std(s1)^2);
clase2=sqrt(std(r2)^2+std(s2)^2);
clase3=sqrt(std(r3)^2+std(s3)^2);
clase4=sqrt(std(r4)^2+std(s4)^2);
clase5=sqrt(std(r5)^2+std(s5)^2);
clase6=sqrt(std(r6)^2+std(s6)^2);
clase7=sqrt(std(r7)^2+std(s7)^2);
clase8=sqrt(std(r8)^2+std(s8)^2);

end;

```

●

## 7. Contenido del CD.

En el Cd se encuentran los siguientes ficheros.

- Tesina final de máster en formato .pdf
- Directorio "programas" con el código fuente utilizados para los cálculos de la misma. Hay un directorio para el código fuente de ArcGis, otro para el de IDL y otro para el de Matlab.
- Directorio con todas las imágenes calculadas.