

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

DEPARTAMENTO DE COMUNICACIONES



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Tesis Doctoral

**Técnicas de detección de cambios
mediante teledetección
para el desarrollo sostenible
y la desertificación**

Soufiane Abdelaziz Azzouzi

Directora:

Dr. Ana Vidal Pantaleoni (Universitat Politècnica de València)

Tesis presentada al Departamento de Comunicaciones,
en el cumplimiento parcial de los requisitos para obtener:
Título de Doctor por la Universitat Politècnica de València
Fecha: enero 2019, Valencia

*Je dédie mon travail de thèse
à ma chère femme Anfal,
à mes chers parents Ahmed et Touatia,
à mes soeurs Sarah, Imene et Aïcha,
à mes frères Omar et Ali,
à mon grand père Abdelkader et ma grand mère Kheira,
à mes tantes Mama, Khadija, Fatma et Djamila,
à mes oncles Tayeb, Nacer, Mechri, Saâd, Hadj, Touati, Abdellah et Nasreddine,
à mon cousin Nouredine,
à mes beaux-parents Abdelkader et Khaouda,
à toute ma famille,
à la familia playa, Otman Toumi, Rabah Boughena, Rachid Ben Abdelouahab et leurs
familles,
à mes frères SidAhmed Mokeddem, Belkacem Chaïm, Salah Eddine Gacem, Said Jalal,
Abdelaziz Hammaoui, Abdelaziz Bouhlassa, Moustafa Sahnoune, Miloud Haloui, Adda
Tahar, Bendhiba Abadlia Bagdad, Mourad Moudjeb, Mohamed Amine Koibich, Moulay
N'bich Cherif, Djamel Eddine Aimouch, Farid Bouchih, et Azzedine Derkaoui,
à notre Imam, cheikh Mohamed Ali et Taha Hendi,
à la mosquée de la ligue islamique et au centre culturel islamique de Valencia (CCIV),
à tous mes collègues de la société EDICOM
à tous mes amis
et à tous les personnes qui m'ont aidé de près ou de loin...*

“Ô mon Seigneur, accroît mes connaissances!” Coran (20/114)

Agradecimientos

Tras muchos años de trabajo, esto parece que por fin tiene un punto final, y no podría haberlo conseguido sin la ayuda, el apoyo, el consejo y el soporte de todos vosotros.

Ante todo, quiero agradecer enormemente a mi directora Dr. Ana Vidal Pantaleoni por su apoyo, paciencia, atención y disponibilidad durante estos años, por darme la oportunidad de desarrollar mi carrera investigadora con ella en el Grupo de Aplicaciones de las Microondas (GAM). Muchísimas gracias.

De igual manera quiero agradecer mi codirector Dr. Hadj Adda Bentounes por su labor en el desarrollo del presente trabajo.

A la unión europea por su excelente programa de Erasmus Mundus (EMMAG), Universidad Abdelhamid Ibn Badis de Mostaganem, Universitat Politècnica de València, por su apoyo material y económico que han dejado factible la investigación y el desarrollo de esta Tesis.

A mis profesores, a mis compañeros, a mis amigos. Todos ellos del GAM de la Universitat Politècnica de València, que me han soportado durante cada minuto en el desarrollo de esta Tesis. Gracias a todos por apoyarme durante estos años.

A mis hermanos, Belkacem Chaïm y SidAhmed Mokeddem, por el apoyo moral. Sin olvidar la ayuda y los consejos de Belkacem Chaïm. Muchas gracias hermanos.

A la familia playa, Otman Toumi, Rabah Boughena, Rachid Ben Abdelouahab y sus familias por compartir los buenos inolvidables recuerdos. Muchísimas gracias familia.

A mi familia, mis padres por su apoyo, esfuerzo durante toda mi carrera de estudios, por darme lo necesario, por motivarme, por escucharme, por confiar en mí y que jamás han dejado de pensar por la llegada del fin de esta Tesis. ¡Muchas gracias Abi!, ¡Muchas gracias Mamá!, por darme tanto sin recibir nada a cambio.

Y especialmente, a ti. A mí me ha costado mucho, pero tú lo has sufrido demasiado. Gracias por estar siempre a mi lado animándome. Gracias Anfal.

Resumen

A lo largo de los últimos años ha ido aumentando el interés por disponer de información del uso y la cobertura del suelo y su cambio en el tiempo. Con la aparición de las imágenes de satélite y la teledetección, ahora se puede obtener y supervisar esta información de la Tierra de forma sistemática. Además, los avances tecnológicos de los sensores hacen que aumente la disponibilidad de imágenes de alta y media resolución en el espectro óptico y en el de microondas. Por otra parte, el problema de la desertificación en zonas áridas está creciendo junto con la concienciación global por el cambio climático. Desde hace décadas, el gobierno argelino gestiona iniciativas y programas para luchar contra el avance del desierto en las zonas agrícolas y las ciudades ubicadas en el norte del país, cerca del desierto del Sáhara. Últimamente, se han empezado a explotar las nuevas fuentes de información de la superficie de la Tierra, cada vez más accesibles, con este propósito. En general, las metodologías de supervisión y monitorización de uso de suelo requieren un alto grado de intervención humana para entrenamiento y validación. El enfoque de esta Tesis consiste en desarrollar técnicas de detección de cambio mediante el análisis semi-automático de imágenes ópticas multitemporales y de microondas disponibles de forma abierta, con especial énfasis en la detección de desertificación en el norte de Argelia.

En primer lugar, se emplea la técnica *Change Vector Analysis* y se estudian sus resultados en dos áreas diferentes con objeto de validar esta metodología de detección de cambios. Para ello, se realizan clasificaciones supervisadas por píxel, habiendo seleccionado las clases adecuadas por cada información de la escena. En esta fase, se comprueban los resultados obtenidos con diferentes tipos de clasificadores. Así, el clasificador *Maximum Likelihood Classifier* es el que proporciona una mejor precisión global, igual a 90,71 %, en los escenarios bajo test. La evaluación de la calidad se realiza mediante matrices de confusión y sus parámetros derivados, tales como la precisión global y el coeficiente kappa. La fase de búsqueda del umbral óptimo es el punto crítico en esta metodología de detección

de cambios. Una posibilidad de establecer el umbral nos lo da el método clásico *Double-Window Flexible Pace Search*. Los resultados de la discriminación del tipo de cambio se muestran mediante las matrices de transición e índices de cambios, y en formato gráfico mediante mapa de cambios.

En segundo lugar, se estudia la detección de cambios aplicada a la desertificación en Argelia mediante datos ópticos. Se desarrolla una metodología basada en la comparación posterior a la clasificación para monitorizar de forma simple la degradación de la tierra. Este método de detección de cambio es el que proporciona los mejores resultados con una precisión global del 95,15 %, tras compararlo con la detección con vectores y considerar diferentes parámetros en ambos métodos. En este caso, el clasificador basado en objetos y la técnica *Support Vector Machine* es el que proporciona los mejores resultados con un 92,91 % en termino de precisión global y un valor del coeficiente kappa igual a 0,91, después de comparar las matrices de confusión y sus parámetros derivados. Consecuentemente, se diseña un método de detección de cambios y se evalúa la evolución del cambio en la ciudad de Biskra (Argelia) durante un período de veinticinco años. Los resultados se disponen en formato estadístico (matrices de transición e índices de cambio) y en formato gráfico mediante mapas de distribución de cambios, obteniendo excelentes resultados con un bajo coste en tiempo de operador humano.

Finalmente, teniendo en cuenta la creciente disponibilidad de imágenes de microondas, se realiza un estudio añadiendo imágenes radar a los datos ópticos en la metodología previamente seleccionada de detección de desertificación. Después de evaluar diferentes configuraciones para introducir la nueva información en la cadena de procesado, se escoge la integración de la imagen radar en polarización vertical-vertical sin filtrado Speckle después de la fase de segmentación. Esta nueva estrategia, empleando imágenes ópticas y de radar, introduce una mejora significativa sobre los resultados anteriormente obtenidos, con 97,05 % de precisión global y 0,96 del coeficiente kappa, ya que las propiedades de la arena seca en la imagen radar hacen que sea más fácilmente identificada. Este nuevo método semiautomático integrando distintos tipos de imágenes reduce el trabajo del analista y produce un informe de detección de cambios fácil de interpretar. La utilidad de este tipo de informe reside en ayudar a las autoridades gubernamentales argelinas a tomar las acciones adecuadas en la lucha contra la degradación de la Tierra.

Resum

Al llarg dels últims anys ha anat augmentant l'interés per disposar d'informació de l'ús i la cobertura del sòl i el seu canvi en el temps. Amb l'aparició de les imatges de satèl·lit i la teledetecció, ara es pot obtenir i supervisar aquesta informació de la Terra de forma sistemàtica. A més, els avanços tecnològics dels sensors fan que augmente la disponibilitat d'imatges d'alta i mitja resolució en l'espectre òptic i en el de microones. D'altra banda, el problema de la desertificació en zones àrides està creixent juntament amb la conscienciació global pel canvi climàtic. Des de fa dècades, el govern algerià gestiona iniciatives i programes per a lluitar contra l'avanç del desert en les zones agrícoles i les ciutats situades en el nord del país, prop del desert del Sàhara. Últimament, s'han començat a explotar les noves fonts d'informació de la superfície de la Terra, cada vegada més accessibles, amb aquest propòsit. En general, les metodologies de supervisió i monitoratge d'ús de sòl requereixen un alt grau d'intervenció humana per a entrenament i validació. L'enfocament d'aquesta Tesi consisteix a desenvolupar tècniques de detecció de canvi mitjançant l'anàlisi semiautomàtica d'imatges òptiques multitemporales i de microones disponibles de forma oberta, amb especial èmfasi en la detecció de desertificació en el nord d'Algèria.

En primer lloc, s'empra la tècnica *Change Vector Analysis* i s'estudien els seus resultats en dues àrees diferents a fi de validar aquesta metodologia de detecció de canvis. Per a això, es realitzen classificacions supervisades per píxel, havent seleccionat les classes adequades per cada informació de l'escena. En aquesta fase, es comproven els resultats obtinguts amb diferents tipus de classificadors. Així, el classificador *Maximum Likelihood Classifier* és el que proporciona una millor precisió global del 90,71% en els escenaris sota test. L'avaluació de la qualitat es realitza mitjançant matrius de confusió i els seus paràmetres derivats, tals com la precisió global i el coeficient kappa. La fase de cerca del llindar òptim és el punt crític en aquesta metodologia de detecció de canvis. Una

possibilitat d'establiment de llindar ens ho dona el mètode clàssic *Double-Window Flexible Pace Search*. Els resultats de la discriminació del tipus de canvi es mostren mitjançant les matrius de transició i índexs de canvis, i en format gràfic mitjançant mapa de canvis.

En segon lloc, s'estudia la detecció de canvis aplicada a la desertificació a Algèria mitjançant dades òptiques. Es desenvolupa una metodologia basada en la comparació posterior a la classificació per a monitorar de forma simple la degradació de la terra. Aquest mètode de detecció de canvi és el que proporciona els millors resultats amb una precisió global del 95,15 % després de comparar-ho amb la detecció amb vectors i considerar diferents paràmetres en tots dos mètodes. En aquest cas, el classificador basat en objectes i la tècnica *Support Vector Machine* és el que proporciona els millors resultats amb una precisió global igual a 92,91 % i un coeficient kappa de 0,91, després de comparar les matrius de confusió i els seus paràmetres derivats. Conseqüentment, es dissenya un mètode de detecció de canvis i s'avalua l'evolució del canvi a la ciutat de Biskra (Algèria) durant un període de vint-i-cinc anys. Els resultats es disposen en format estadístic (matrius de transició i índexs de canvi) i en format gràfic mitjançant mapes de distribució de canvis, obtenint excel·lents resultats amb un baix cost en temps d'operador humà.

Finalment, tenint en compte la creixent disponibilitat d'imatges de microones, es realitza un estudi afegint imatges radar a les dades òptiques en la metodologia prèviament seleccionada de detecció de desertificació. Després d'avaluar diferents configuracions per a introduir la nova informació en la cadena de processament, es tria la integració de la imatge radar en polarització vertical-vertical sense filtrat Speckle després de la fase de segmentació. Aquesta nova estratègia, emprant imatges òptiques i de radar, introdueix una millora significativa sobre els resultats anteriorment obtinguts, amb 97,05 % de precisió global i 0,96 del coeficient kappa, ja que les propietats de l'arena seca en la imatge radar fan que siga més fàcilment identificada. Aquest nou mètode semiautomàtic integrant diferents tipus d'imatges redueix el treball de l'analista i produeix un informe de detecció de canvis fàcil d'interpretar. La utilitat d'aquest tipus d'informe resideix a ajudar les autoritats governamentals algerianes a prendre les accions adequades en la lluita contra la degradació de la Terra.

Abstract

Over the last few years, the interest on the use of land use, land cover and its change in the time has grown. With the appearance of satellite images and Remote Sensing techniques, this type of Earth information can be obtained in a systematic way. In addition, the development of sensor technologies increases the availability of high and medium resolution images in the optical and microwave spectrum. On the other hand, the issue of desertification in arid zones is growing joined to the global awareness for climate change. For the last decades, the Algerian government has managed initiatives and programs to combat desertification in agricultural areas and cities located in the north of the country, near Sahara desert. Recently, they have started exploiting new sources of land cover information for this purpose. In general, land use and land cover monitoring methodologies require a high degree of human intervention for training and validation steps. The main focus of this Thesis is to develop change detection techniques through semiautomatic analysis of freely available optical and microwave images, with special emphasis on the detection of desertification in the north of Algeria.

Firstly, Change Vector Analysis is studied in two different zones in order to validate this change detection technique. For that purpose, supervised classification per pixel is employed with the selection of the appropriate classes for each scene information. In this step, comparison among different types of classifiers is done and Maximum Likelihood Classifier provides the better accuracy equal to 90,71 %. Quality evaluation is given by matrices of confusion and its derived parameters, such as global accuracy and kappa coefficient. A critical point in change detection methodology is optimal threshold selection. One possibility for it is given by the classical method Double-Window Flexible Pace Search. The results of change detection are given by transition matrices, change indexes and change maps.

Secondly, change detection applied to the issue of desertification in Algeria is studied

using optical data. A methodology based on post classification comparison is developed to monitor the degradation of the Earth in a simple way. This method of change detection provides the best results with a value of 95,15 % in overall accuracy, after the comparison with Change Vector Analysis and considering different processing parameters in both methods. In this case, the Support Vector Machine classifier based on objects is the one that provides the best results with a remarkable global accuracy of 92,91 % and kappa coefficient equal to 0,91, after comparing the confusion matrices and their derived products. Consequently, a change detection method is designed and evaluated in the city of Biskra (Algeria) during a period of twenty-five years. The results are available in statistical format (transition matrices and change indexes) and in graphical format using change distribution maps. The excellent results are obtained with low operator time.

Finally, taking into account the increasing availability of microwave images, the addition of radar images to the optical data in the previously selected desertification detection methodology is carried out. After evaluating different configurations, the integration of the radar image in vertical-vertical polarization without Speckle filtering after the segmentation step is chosen. This new strategy employing optical and radar images provides a significant improvement over previous results (with a value of 97,05 % in global accuracy and 0,96 in kappa coefficient), since the properties of dry sand in the radar image make it more easily identifiable. This new semiautomatic method integrating different types of images reduces the analyst's work and produces an easily interpretable change detection report. The usefulness of this type of report lies in helping the Algerian government authorities to take appropriate actions to fight against land degradation.

Índice general

Resumen	VII
Resum	IX
Abstract	XI
Índice general	XIII
1 Introducción	1
1.1 Motivación y objetivos	1
1.2 Estado del arte	3
1.2.1 Revisión de trabajos centrados en consideraciones generales previas	6
1.2.2 Revisión de las técnicas de detección de cambios	7
1.2.2.1 Métodos basados en Álgebra	8
1.2.2.2 Métodos basados en Transformación	12
1.2.2.3 Métodos basados en Clasificación	15
1.2.2.4 Modelos avanzados	19
1.2.2.5 Métodos basados en SIG	22
1.2.2.6 Métodos basados en Análisis Visual	23
1.2.2.7 Otras técnicas de detección de cambios	25
1.2.3 Estudio comparativo de técnicas de detección de cambios	25
1.2.4 Revisión de trabajos relacionados con la selección de umbral	27
1.2.5 Revisión de trabajos relacionados con la selección de datos	28
1.2.6 Revisión de trabajos relacionados con la evaluación de precisión	29
1.3 Organización de la tesis	31

2	Degradación medioambiental y teledetección	33
2.1	Desastres naturales y de origen humano	33
2.1.1	Daños provocados por desastres naturales	34
2.1.2	Cuantificación del cambio	35
2.1.3	Caso de estudio: desertificación	36
2.2	Observación de la tierra por satélite	38
2.2.1	Tipos de imágenes satelitales	38
2.2.2	Concepto de resolución	41
2.2.3	Misiones de satélites de teledetección	42
2.2.3.1	Landsat	43
2.2.3.1.1	Landsat-5	43
2.2.3.1.2	Landsat-7	43
2.2.3.1.3	Landsat-8	43
2.2.3.2	Terra	45
2.2.3.3	Sentinel-2	45
2.2.3.4	SPOT	46
2.2.3.5	Sentinel-1	48
2.2.3.6	TerraSAR-X y TanDEM-X	50
3	Técnicas básicas de análisis	51
3.1	Corrección de imágenes de satélite	51
3.1.1	Corrección radiométrica	51
3.1.1.1	Corrección atmosférica	53
3.1.2	Corrección geométrica	53
3.1.2.1	Registro	54
3.1.3	Filtro Speckle	55
3.2	Clasificación	56
3.2.1	Clasificación por píxel	56
3.2.1.1	Tipos de clasificadores por píxeles	56
3.2.2	Clasificación por objetos	58
3.2.2.1	Tipos de clasificadores por objetos	60
3.3	Detección de cambios	63
3.3.1	Análisis Vectorial de Cambio (CVA)	63
3.3.2	Comparación post-clasificación	63
3.3.3	Interpretación visual	63
3.4	Evaluación de resultados	64
3.4.1	Matriz de confusión	64
3.4.1.1	Coefficiente kappa y precisión global	65
3.4.2	Matriz de transición e índices de cambio	66

4 Detección con vectores CVA	69
4.1 Introducción	69
4.2 Áreas de estudio	70
4.3 Correcciones de imagen	72
4.4 Detección de cambio	74
4.4.1 Selección de umbral	77
4.4.2 Discriminación del tipo de cambio	80
4.5 Clasificación de las imágenes y resultados	80
4.6 Discusión	95
5 Detección de desertificación mediante clasificación por objetos e integración de datos radar	97
5.1 Introducción	97
5.2 Área de estudio	100
5.3 Corrección de imágenes	106
5.4 Detección de desertificación a largo plazo con datos ópticos	106
5.4.1 Clasificación de las imágenes ópticas	107
5.4.2 Métodos de detección de cambio	112
5.4.2.1 Selección de umbral	112
5.4.2.2 Comparación de técnicas de detección de cambio	114
5.4.3 Resultados y discusión	115
5.5 Detección de desertificación a corto plazo con datos ópticos y radar	123
5.5.1 Corrección de imágenes radar	123
5.5.2 Integración de datos radar en la clasificación	124
5.5.3 Resultados de la clasificación y discusión	128
5.5.4 Detección de cambio	133
5.5.5 Resultados de detección de cambio y discusión	133
6 Conclusiones y líneas futuras	139
6.1 Conclusiones	139
6.2 Líneas futuras de investigación	142
A Lista de publicaciones	145
A.1 Artículos publicados en revistas	145
A.2 Artículos publicados en conferencias internacionales	145
A.3 Artículos publicados en conferencias nacionales	146
Lista de Figuras	147

Lista de Tablas	149
Acrónimos	153
Bibliografía	157

Capítulo 1

Introducción

Este capítulo presenta el problema tratado en esta Tesis, haciendo una revisión de las metodologías empleadas por la comunidad científico-técnica para la detección de cambios mediante teledetección. Se presentan también los objetivos planteados en el desarrollo de la Tesis.

1.1 Motivación y objetivos

El análisis espacio-temporal de las imágenes de satélite es una línea de investigación cada vez más relevante para el estudio de fenómenos dinámicos y para su interpretación. Con la aparición de sensores de media y alta resolución espacial, espectral y temporal, obtenemos un volumen de datos rico en información, que nos permite realizar un seguimiento de la degradación del terreno mediante la teledetección. Las series temporales de imágenes satelitales representan actualmente una importante fuente de información para la monitorización de la superficie de la Tierra a diferentes escalas. Las aplicaciones son múltiples y abarcan varias líneas. Entre estas líneas, esta tesis se enfoca hacia la degradación de la Tierra y en particular la desertificación.

El fenómeno de desertificación es un problema global, ya que disminuye la productividad de la Tierra en general. La desertificación se define de varias maneras, sin embargo la *United Nations Convention to Combat Desertification (UNCCD)* dice que: “la desertificación es la degradación de la tierra en zonas áridas, semiáridas y subhúmedas secas, como resultado de diversos factores, incluyendo la variación climática y las actividades humanas”. Actualmente, el 24 % de la superficie terrestre está degradada, afectando a alrededor de 1500 millones de personas, la mayoría de las cuales viven en países en vías de

desarrollo. La UNCCD declaró que cada año se pierden aproximadamente 42 millardos de dólares en ingresos mundiales debido a la desertificación. Además del impacto inmediato sobre los medios de subsistencia de las personas, la desertificación está conectada con otros problemas globales muy graves, ya que va acompañada de la pérdida de diversidad biológica y contribuye al cambio climático global.

Argelia es el país más grande de África (2 381 741 km²) y está afectado seriamente por la desertificación. De hecho, de los 238 millones de hectáreas de superficie, 200 millones de hectáreas se encuentran en la zona sahariana, 20 millones de hectáreas en zona esteparia con suelos muy frágiles y sujetos al fenómeno de desertificación, y el resto (alrededor de 18 millones de hectáreas) pertenecen a zonas montañosas. Las áreas degradadas detectadas de forma reciente están situadas en su mayoría al norte del país. En Argelia, la desertificación afecta a grandes áreas de territorio y, en consecuencia, provoca consecuencias sociales, económicas y ambientales. Tal y como se mencionó anteriormente, la degradación es compleja y resulta de la aparición de varios factores, incluida la variación climática y las actividades humanas. Pero es probable que el cambio climático sea el principal factor responsable. Las evaluaciones de la degradación de la Tierra se han convertido en un elemento importante en la política, y en la toma de decisiones hacia la gestión del desarrollo sostenible. Como consecuencia, contribuyen de una forma importante en la lucha contra la desertificación y a preservar el equilibrio ambiental.

Las observaciones sistemáticas a largo plazo de la cubierta y el uso de la Tierra (*Land-Use and Land-Cover (LULC)*) son esenciales para permitir a los científicos cuantificar las tasas de cambio y su variabilidad a lo largo del tiempo. Las técnicas de detección de cambios LULC tienen un impacto importante para la monitorización y la supervisión del cambio global. Se han desarrollado diferentes técnicas y metodologías en los últimos años gracias a la creciente disponibilidad de los productos de la teledetección. El trabajo aquí presentado puede contribuir así al desarrollo de una estrategia operativa sólida y a un plan de desarrollo para la investigación científica sobre la desertificación, y así aumentar la conciencia a nivel local, nacional e internacional.

El objetivo general de este estudio es obtener información espacio-temporal precisa y mejorada, para evaluar y modelar el cambio en la superficie mediante la selección de métodos apropiados de entre los métodos tradicionales, y mejorarlos para integrar datos ópticos y de radar. Las metodologías desarrolladas están condicionadas por la disponibilidad de los datos de satélite que ofrecen *United States Geological Survey (USGS)* y *European Space Agency (Agencia Espacial Europea) (ESA)*, de forma que haya una reducción de costes para las autoridades gubernamentales.

El desarrollo de esta Tesis está dividido en dos grandes partes, 1) aplicar las técnicas de detección de cambios basadas en vectores de cambio y evaluarlos en distintas áreas

de estudio respecto a sus dinámicas de cambio, 2) estudiar la desertificación y desarrollar metodologías de detección de cambios con datos ópticos y de radar en sus distintas polarizaciones. Los objetivos de esta Tesis son así los siguientes:

1. Usar la técnica *Change Vector Analysis (CVA)* para detectar el cambio y sus dinámicas de evolución en dos áreas diferentes: Pekín (China) y Aïn Defla (Argelia). En el proceso, encontrar el mejor clasificador por píxel y desarrollar el método *Double-Window Flexible Pace Search (DFPS)* para determinar el umbral adecuado. Discriminar los cambios mediante las matrices de transición, índices y mapas de cambio. Obtener la efectividad del método CVA en una zona dinámica y en otra con poco cambio, para observar su influencia en los resultados.
2. Proponer una metodología de detección de desertificación a largo plazo con datos ópticos y seleccionar el mejor clasificador de entre varias opciones de clasificador por píxel y por objetos. Elegir el mejor método de detección de cambio entre *Change Vector Analysis in Posterior Probability Space (CVAPS)* y *Post Classification Comparison (PCC)*. Evaluar los movimientos de las dunas de arena en relación con el cambio climático durante un periodo de 25 años en Biskra, Argelia.
3. Proponer una metodología de detección de desertificación a corto plazo que incluya datos ópticos y de radar. Valorar los cambios detectados mediante los índices de cambio en la ciudad de Biskra, Argelia durante un año.

1.2 Estado del arte

La detección de cambios es el proceso de identificación de diferencias en el estado de un objeto o fenómeno al observarlo en diferentes momentos [1]. En concreto, la detección oportuna y precisa del cambio de las características de la superficie de la Tierra proporciona la base para una mejor comprensión de las relaciones e interacciones entre los fenómenos humanos y naturales, con el objeto de gestionar y utilizar mejor los recursos. Así, la detección de cambios implica la utilización de series de datos temporales para analizar cuantitativamente sus efectos. Debido a las ventajas de adquisición repetitiva de datos, su visión sinóptica y formato digital adecuado para el procesamiento informático, los datos de teledetección, tales como *Thematic Mapper (TM)* de Landsat, el programa *Satellite Pour l'Observation de la Terre (SPOT)*, las imágenes *Synthetic Aperture Radar (SAR)* y las imágenes de baja resolución *Advanced Very High Resolution Radar (AVHRR)* se han convertido en las principales fuentes de información para diferentes aplicaciones de detección de cambios durante los últimos años. Las aplicaciones más relevantes en detección de cambios que utilizan tecnologías de teledetección son las siguientes:

- Cambio en uso de la tierra y cubierta vegetal [2–14], y monitorización de cultivos [15].
- Cambio en bosques y masa forestal [16–29].
- Mortalidad forestal, defoliación y evaluación de daños forestales [30–37].
- Desertificación, deforestación y regeneración, y tala selectiva [38–49].
- Incendios forestales [50–57].
- Cambio en el medio ambiente [58–62].
- Cambios en el paisaje [63–67]; detección de deslizamientos de tierra [68].
- Cambio urbano [69–76].
- Cambio climático y su impacto en humedales [77–85]; monitorización de sequía [86]; monitorización de inundaciones [87].
- Otras aplicaciones tales como monitorización de ambientes marinos costeros [88] y medida de masa glacial [89].

A lo largo del tiempo se han desarrollado una gran variedad de técnicas de detección de cambios. Algunas de ellas se han resumido y revisado en [1, 9, 90–94]. Debido a la importancia de la monitorización del cambio de las características de la superficie de la Tierra, la investigación en este campo es muy dinámica, y se desarrollan constantemente nuevas técnicas. Por ejemplo, se destaca la aparición de las siguientes metodologías: el análisis de mezcla espectral [95], el modelo de dosel *Li-Strahler* [35], la transformación *Chi-square* [72], el conjunto *Fuzzy* [96], las redes neuronales artificiales (ANN) [36], la integración de datos múltiples [97], la detección de cambios mediante la técnica de CVA [98], *Improved Change Vector Analysis (ICVA)* [99], *Modified Change Vector Analysis (MCVA)* [100] y CVAPS [101].

En [102] los autores indican que un buen método de detección de cambio debe aportar la siguiente información:

- Cambio de área y tipo de cambio producido.
- Distribución espacial del cambio.
- Tendencia de cambio de cobertura terrestre.
- Evaluación de la precisión de los resultados.

El mismo trabajo indica tres pasos principales al implementar un proyecto de detección de cambios:

- Preprocesamiento de imágenes incluyendo rectificación geométrica y registro de imágenes, corrección radiométrica y atmosférica, y corrección topográfica si el área de estudio se encuentra en regiones montañosas.
- Selección de técnicas adecuadas para implementar análisis de detección de cambios.
- Evaluación de precisión.

La precisión de los resultados de detección de cambios depende de muchos factores, que incluyen:

- Registro geométrico preciso entre imágenes multitemporales.
- Calibración o normalización entre imágenes multitemporales.
- Disponibilidad de datos de referencia del área de estudio.
- La complejidad del paisaje en el área de estudio.
- Los métodos o algoritmos utilizados.
- Habilidades y experiencia del analista.
- Conocimiento y familiaridad del área de estudio.
- Restricciones de tiempo y costes.

Debido a la complejidad de los factores involucrados, a menudo distintos estudios llegan a conclusiones diferentes y a veces contrapuestas acerca de qué técnicas de detección de cambios son más adecuadas. En la práctica, no es fácil seleccionar el mejor algoritmo para un proyecto de detección de cambios concreto. Por lo tanto, es útil revisar las distintas técnicas para entender cómo pueden ser utilizadas en problemas específicos. Así, una vez se aísla un problema en una zona y se seleccionan los datos disponibles, la correcta identificación de una técnica adecuada adquiere gran importancia.

A continuación se revisan trabajos que analizan aspectos generales de la detección de cambios, trabajos que describen distintas metodologías, se revisan sus aplicaciones y se proporcionan recomendaciones para la selección adecuada de métodos de detección de cambio.

1.2.1 Revisión de trabajos centrados en consideraciones generales previas

Existen cuatro aspectos importantes de la detección de cambios para la monitorización de los recursos naturales (ver [103]): detección; identificación de su naturaleza; medición del área de cambio y por último evaluación de su patrón espacial. Cualquier trabajo relacionado con este campo de trabajo debe intentar cubrir el máximo de estos aspectos, ya que la mera decisión sobre si un píxel ha sufrido cambio o no, no suele aportar suficiente información para un gestor de recursos.

En [104] los autores indican cinco categorías de causas que influyen en el cambio de cobertura de la tierra: cambios naturales a largo plazo en las condiciones climáticas; procesos geomorfológicos y ecológicos, tales como la erosión del suelo y la sucesión de vegetación; alteraciones de la cubierta vegetal y paisajes inducidas por el ser humano, tales como la deforestación y la degradación de la tierra; variabilidad climática anual; y el efecto invernadero causado por las actividades humanas.

Una implementación exitosa de detección de cambios con el uso de teledetección requiere una consideración del sensor. La resolución temporal, espacial, espectral y radiométrica de los datos tiene un impacto significativo en el éxito de un proyecto de detección de cambios en teledetección. Asimismo, los factores ambientales más importantes incluyen las condiciones atmosféricas, la humedad del suelo y las características fenológicas, tal y como se describe en [91].

El primer paso, común para los distintos métodos, consiste en la preparación y adecuación de los datos. Las etapas más importantes en el preprocesado de datos son: correcciones geométricas, radiométricas y atmosféricas, y co-registro de imagen multitemporal. La importancia del co-registro espacial de imágenes multitemporales es obvia porque se producirán resultados falsos de detección de cambios si las imágenes se co-registran incorrectamente [99, 105]. La conversión de Niveles Digitales (ND) a radiancia o superficie reflectante es también clave para el análisis cuantitativo de imágenes multitemporales.

Se han desarrollado una gran variedad de métodos para la normalización o corrección radiométrica y atmosférica, tales como la calibración relativa, *Dark Object Subtraction (DOS)* y la segunda simulación de la señal del satélite en el espectro solar 5S o 6S [106]. Además, si el área de estudio es accidentada o montañosa, puede ser necesaria la corrección topográfica usando su correspondiente *Digital Elevation Model (DEM)* [107]. En resumen, antes de implementar un análisis de detección de cambios propiamente dicho se deben cumplir las siguientes condiciones:

- Calibración y normalización radiométrica y atmosférica de imágenes multitemporales.

- Registro preciso de las imágenes multitemporales.
- Consideración de un estado fenológico semejante en las imágenes multitemporales.
- Selección de una resolución espacial y espectral semejante de las imágenes analizadas.

Existen muchos tipos de datos de teledetección disponibles para las aplicaciones de detección de cambios: programas Landsat, SPOT, imágenes de alta resolución, datos radar y otros. Así, la selección de datos es un proceso crucial. Es interesante emplear el mismo sensor para las fechas a comparar, ya que asegura una misma resolución radiométrica y espacial. Además, las fechas de adquisición se deben escoger cuidadosamente con el fin de minimizar los efectos de fuentes externas como el ángulo de iluminación solar, las diferencias estacionales y las fenológicas [108].

1.2.2 Revisión de las técnicas de detección de cambios

El objetivo principal de la detección del cambio es comparar la representación espacial de un punto en dos instantes de tiempo, controlando todas las variables que no son de interés, y medir los cambios causados por las diferencias en las variables de interés [6]. Según [49], lo esencial es que los cambios de los objetos de interés reflejen la variación en los valores de reflectividad o texturas locales, siendo separables de los cambios causados por otros factores tales como las diferencias en condiciones atmosféricas, iluminación, ángulo de observación, y humedad del suelo. Debido a que la detección de cambios digitales se ve afectada por limitaciones espaciales, espectrales, temáticas y temporales, y porque existen muchas técnicas, la selección de un método o algoritmo adecuado para un proyecto de investigación determinado es una tarea compleja.

Los métodos de detección de cambios se pueden agrupar en siete categorías: (1) Álgebra, (2) Transformación, (3) Clasificación, (4) Modelos Avanzados, (5) Sistemas de Información Geográfica (SIG), (6) Análisis Visual y (7) otras técnicas. Las tablas 1.1, 1.2, 1.3, 1.4, 1.5 y 1.6 resumen las principales características, ventajas, desventajas y puntos clave de las primeras seis categorías. En estas tablas también se destaca su correspondiente nivel de complejidad. La séptima categoría incluye aquellas técnicas de detección de cambios que no son adecuadas para agruparse en una de las seis categorías anteriores, y que aún no están muy extendidas en la práctica. Debido a ello, esta séptima categoría no se discute en detalle. La mayoría de las técnicas presentadas utilizan para la detección de cambios datos con una resolución espacial semejante a la proporcionada por Landsat, SPOT o *Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)*.

1.2.2.1 Métodos basados en Álgebra

Los métodos basados en Álgebra incluyen diferenciación de imágenes, regresión de imágenes, relación de imágenes, diferenciación de índices de vegetación, análisis de vectores de cambio CVA y sustracción de fondo. Estos algoritmos tienen una característica común, que es seleccionar umbrales para determinar áreas modificadas. Estos métodos (excluyendo CVA) son relativamente simples, directos, fáciles de implementar e interpretar, pero no pueden proporcionar matrices completas de información de cambio.

CVA es una extensión conceptual de la diferenciación de imágenes. Este método puede detectar todos los cambios mayores que los umbrales seleccionados y puede proporcionar información de cambio detallada. Una desventaja de este grupo de métodos es la dificultad de seleccionar umbrales adecuados para identificar las áreas modificadas. Así pues, en esta categoría hay dos aspectos críticos para los resultados de detección de cambios: la selección de bandas de imagen o índices de vegetación y la selección de umbrales.

Los autores en [109] presentan la diferencia de datos de relación de banda y una nueva técnica de umbral para identificar áreas cambiadas. Los autores en [110] encuentran la utilidad de los datos visibles de la banda roja en el análisis de detección de cambios tanto en áreas de vegetación como en áreas urbanas.

El trabajo presentado en [111] también indica que la diferenciación de la imagen de banda roja proporciona mejores resultados de detección de cambios de vegetación que el uso del *Normalized Difference Vegetation Index (NDVI)* en las áreas áridas y semiáridas en el suroeste de Estados Unidos.

La contribución de [112] es que los datos visibles de la banda roja proporcionan la identificación más precisa del cambio espectral para su área de estudio semiárida en el noroeste de Nigeria (sur del Sahel, África).

En [72] se compara la diferenciación de imágenes, el método de regresión, la transformación *Kauth Thomas (KT)* o la transformación Tasselled Cap y la transformación *Chi-square* para la detección de cambios de uso del suelo urbano en el área del valle del Lago Salado (Utah, Estados Unidos), usando datos de Landsat TM. En este trabajo, se llega a la conclusión de que la diferenciación y la regresión de la banda TM 3 son los mejores métodos. Sin embargo, ninguno de los algoritmos o selecciones de banda utilizados es claramente superior a los demás.

El autor en [30] examina la utilidad de la diferenciación de imagen, relación de imagen y diferenciación de índice de vegetación para detectar defoliación de polilla gitana y encuentra que una diferencia de la relación MSS7/MSS5 es más útil en la delimitación del área defoliada que cualquier diferencia o relación de un solo par de bandas.

El trabajo presentado en [113] descubre que la relación entre los datos multisensoriales y de imagen de satélite multitemporal produce una mayor precisión de detección de cambios que el *Principal Component Analysis (PCA)* y es útil como una técnica de mejora del cambio de uso del suelo. La relación de las bandas roja e infrarroja cercana del satélite Landsat MSS-SPOT de Muy Alta Resolución (MAR) produce una precisión de detección de cambio sustancialmente mayor (aproximadamente un 10 % mejor) que la relación de bandas similares de un Landsat MSS-Landsat TM multitemporal.

Los autores en [114] utilizan diferenciación de imágenes, relación de imágenes y diferenciación NDVI para detectar cambios en el uso del suelo en una zona minera de carbón en Jharia (India). Así, encuentran que no existe diferencia significativa entre estos métodos para detectar cambios en el uso del suelo y a cada método se le puede atribuir alguna ventaja sobre los demás.

El trabajo presentado en [115] compara siete índices de vegetación de tres fechas diferentes de datos de MSS para la detección de cambios en la cobertura terrestre y concluye que la técnica de diferenciación NDVI produce la mejor detección de cambio en vegetación.

El autor en [116] revisa y evalúa cinco métodos: diferenciación de imágenes univariadas, diferenciación de imágenes mejorada, diferenciación de índices de vegetación, diferenciación posterior a la clasificación, y CVA. Concluye que CVA destaca sobre los demás al proporcionar valiosos detalles cualitativos sobre la naturaleza del cambio.

Los autores en [117] comparan la técnica de diferenciación sobre NDVI, PCA y el compuesto de color rojo, verde y azul RGB-NDVI para la detección de la tala de bosques tropicales y el rebrote de vegetación en la Reserva de la Biosfera Maya de Guatemala. Encuentran que el método que emplea las bandas RGB-NDVI proporciona la mejor precisión global con un valor de 85 %.

Por lo tanto, en la categoría de detección de cambios basada en Álgebra, la diferenciación de imágenes es el método más utilizado en la práctica. La diferenciación de la banda visible roja ha demostrado ser adecuada para la detección de cambios en entornos áridos y semiáridos, pero no está claro que esto sea cierto en otros entornos, tales como las regiones húmedas tropicales. Diferentes autores han llegado a diferentes conclusiones sobre qué método proporciona mejores resultados entre: relación de imagen, diferenciación de índice de vegetación, regresión de imagen y aproximaciones de CVA. Esto es debido a que los resultados varían dependiendo de las características de las áreas de estudio y los datos de imagen utilizados.

El método de sustracción de fondo no se suele utilizar debido a sus pobres resultados. Sin embargo, los autores en [118] usan con éxito este método de sustracción de fondo para

detectar cambios locales de movimientos. Asimismo, los autores en [119] lo aplican a la detección de sombra.

La tabla 1.1 hace un resumen general de los métodos analizados en la categoría de Álgebra con sus características principales, ventajas, desventajas y puntos clave.

Tabla 1.1: Métodos de detección de cambios de la categoría Álgebra 1.2.2.1.

Método	Características	Ventajas	Desventajas	Factor clave
Diferencia [15, 116, 120]	Resta de dos imágenes	Desarrollo e interpretación simple	No proporciona matriz de cambio detallada, requiere selección de umbral	Identificar bandas y umbrales
Regresión [72]	Estima valores de regresión de la segunda fecha y aplica diferenciación sobre ella	Reduce efectos generados por sensores, atmosféricos	Complejidad en la función de regresión	Desarrollar regresión, escoger bandas y umbrales
División [114]	Divide dos imágenes, banda a banda	Reduce efectos de iluminación, sombra y topografía	El rango obtenido debe normalizarse	Identificar bandas y umbrales
Diferencia de índice de vegetación [19, 86, 111, 115, 117]	Primero calcula índices de vegetación para cada fecha y luego los resta	Resalta diferencias en la firma espectral, reduce efectos topográficos y de iluminación	Aumenta el ruido	Identificar índices de vegetación y umbrales
Análisis Vectorial de Cambio (CVA) [101, 121–125]	El vector de cambio espectral describe dirección y magnitud de cambio	Procesa cualquier cantidad de bandas y produce información detallada	Dificultad en identificar las trayectorias de cambio	Define umbrales e identifica trayectorias de cambio
Sustracción de fondo [118, 119]	Se filtra paso bajo la imagen original y se le resta al original	Simplicidad	Precisión baja	Desarrollar la imagen de fondo

1.2.2.2 Métodos basados en Transformación

La categoría de Transformación incluye las transformaciones *Principal Component Analysis (PCA)*, *Kauth Thomas (KT)*, *Gram-Schmidt (GS)* y *Chi-square*. La ventaja de estos métodos es que reducen la redundancia de datos entre bandas y enfatizan la información en diferentes componentes derivados. Sin embargo, no pueden proporcionar matrices de cambio detalladas y requieren la selección de umbrales para identificar las zonas modificadas. Además, presentan otra desventaja en su dificultad para interpretar y etiquetar la información de cambio en las imágenes transformadas.

Los autores en [126] usan PCA y diferencias de imágenes de transformación KT para detectar cambios en la cubierta terrestre de imágenes *Multispectral Scanner (MSS)* y TM multitemporales. Concluyen que diferenciar el verdor (segundo eje de la transformada) y el brillo (primer eje de la transformada) de las imágenes de la transformación KT de datos MSS y TM es la técnica más apropiada para detectar cambios en la cobertura de datos de múltiples sensores. En otro estudio [127], los autores estudian la diferenciación de imágenes, PCA y KT para la detección de cambios en la cubierta terrestre y encuentran que las imágenes asociadas con cambios en el verdor y los cambios en la reflectividad en el infrarrojo cercano podrían detectar cambios en el tipo de cultivo y el estado de la vegetación en general.

Los autores en [128] usan la PCA para detectar cambios en imágenes multitemporales polarimétricas SAR y concluyen que el método PCA es efectivo cuando las bandas en distintas polarizaciones se capturan simultáneamente. Los autores en [129] comparan la técnica PCA estándar y la no estándar y la diferenciación de imágenes. Descubren que la PCA estándar identifica mejor el cambio. Otros estudios también llegan a la conclusión de que la técnica PCA estándar es mejor que su versión no estándar [126, 130, 131].

Los autores en [132] estudian la desertificación en Azraq (Jordania) en un periodo de 30 años con la transformación KT, y descubren que el método Tasselled Cap es capaz de detectar cambios de desertificación en el área de estudio.

El autor en [133] compara la superposición de imágenes, la diferenciación de imágenes, la técnica PCA y la comparación post-clasificación para la detección de cambios de cobertura terrestre en el área de Ikitelli (Estambul, Turquía). Demuestra que la técnica PCA y la comparación posterior a la clasificación resaltan las diferencias atribuidas a los cambios, señalando que cada uno de ellos destaca en algún mérito respecto a la información extraída.

En el artículo [134], los autores utilizan técnicas de detección de cambios lineales para cartografiar la mortalidad forestal utilizando datos de Landsat TM y encuentran que la técnica PCA y la transformación de KT multitemporal son mejores que el proceso de

ortogonalización GS, y que los cambios en la humedad KT son los indicadores individuales más fiables del cambio de bosque.

Los autores en [135] comparan los índices de vegetación NDVI, *Soil Adjusted Vegetation Index (SAVI)*, *Modified Soil Adjusted Vegetation Index (MSAVI)* y proporción de banda TM (7/4), PCA y KT. Así, encuentran que el método de KT proporciona mejores resultados de detección de fuegos de bosques en terreno montañoso en Arizona (EEUU) y Nuevo México.

Para mejorar la precisión, se pueden combinar diferentes técnicas de detección de cambios. Por ejemplo, en [136], se utiliza la diferenciación de imágenes de pares de bandas en cada banda espectral. Posteriormente, utiliza la técnica PCA para la imagen de diferencias multispectrales y finalmente aplica lógica difusa para combinar información de cambio en diferentes imágenes de componentes de cambio en una sola imagen. Se demuestra que este sofisticado método proporciona mejores resultados que la diferenciación simple de imágenes.

En [21] se estudia el cambio forestal mediante una comparación de índices de vegetación para diferentes fechas de imágenes. Los índices de vegetación incluyen brillo, verdor y humedad de la transformación KT, así como el índice NDVI entre otros. Luego se utiliza la distancia Jeffries-Matusita (distancia J-M) para la selección óptima de características. Se demuestra que los cambios en el brillo y el verdor identifican las características más importantes del cambio del dosel forestal y que éstos se pueden expresar adecuadamente como una diferencia normalizada o un segundo componente principal.

Las categorías de Transformación, PCA y KT son los métodos más usados para detectar información de cambio/no-cambio. El método KT parece útil en muchas aplicaciones de detección de cambios. Una ventaja de la transformación KT sobre PCA es que los coeficientes de transformación KT son independientes de las escenas de la imagen, mientras que la transformada PCA depende de las escenas de la imagen. Los métodos GS y *Chi-square* se emplean en menor medida debido a su complejidad en relación a las transformaciones PCA y KT. Además, los métodos GS y *Chi-square* no están disponibles en la mayoría de los paquetes de software comercial de procesamiento de imágenes de teledetección. La tabla 1.2 resume los métodos de detección de cambios de la categoría Transformación y sus características.

Tabla 1.2: Métodos de detección de cambios de la categoría Transformación 1.2.2.2.

Método	Características	Ventajas	Desventajas	Factor clave
Análisis de Componentes Principales (PCA) [120, 126–129, 134, 137]	Se aplica análisis PCA a todos los datos a la vez o las imágenes por separado	Reducir redundancia y enfatizar diferencias	Difícil interpretación. Falta información completa del cambio. Identificar umbrales	Habilidad del analista y seleccionar umbrales
Tasselled Cap (KT) [132, 134, 138]	Funcionamiento similar al PCA con la transformada KT, con tres componentes: brillo, verdor y humedad	Reduce redundancia y enfatiza diferencias. Transformada KT independiente de la escena	Difícil interpretación. Falta información completa del cambio. Identificar umbrales. Requiere corrección atmosférica precisa	Habilidad del analista y seleccionar umbrales
Gram Schmidt (GS) [1, 134, 139]	GS ortogonaliza vectores espectrales y produce: brillo, verdor, humedad y un componente de cambio	Resultados fiables	Dificultad en asociar tipos de cambio con más de un componente individual	Requerir análisis visual previo
Chi-square [72, 140, 141]	Calcula el valor digital de la imagen del cambio	Emplea varias bandas simultáneamente para una única imagen de cambio	Puede fallar cuando calcula valores iguales a 0. La dirección de cambio es difícil de obtener	Trata la imagen como un proceso aleatorio <i>Chi-square</i>

1.2.2.3 Métodos basados en Clasificación

El grupo de métodos basados en Clasificación incluye la comparación posterior a la clasificación, el análisis combinado temporal-espectral, la detección de cambios del algoritmo de maximización de las expectativas *Expectation-Maximization algorithm (EM)*, la detección de cambios no supervisados, la detección de cambios híbridos y las técnicas de redes neuronales *Artificial Neural Networks (ANN)*. Estos métodos se basan en imágenes clasificadas, en las que la calidad y la cantidad de datos de muestra para el entrenamiento son cruciales para producir resultados de clasificación de buena calidad. La principal ventaja de estos métodos es su capacidad de proporcionar una matriz de información de cambio y reducir el impacto externo de las diferencias atmosféricas y ambientales entre las imágenes multitemporales. Sin embargo, la selección de conjuntos de muestras de entrenamiento de alta calidad y suficientemente numerosos es una tarea difícil y costosa en tiempo de operador. Este hecho se acentúa en el caso de la clasificación de grandes archivos históricos de imágenes. Así pues, su principal desventaja está asociada a los costosos y lentos procedimientos de entrenamiento en el caso de que se escoja un método de clasificación supervisado.

En el trabajo presentado en [142], se describe como la técnica PCA de imágenes multitemporales combinada con una clasificación supervisada de máxima verosimilitud puede modelar con éxito el cambio de uso del suelo urbano en el delta del río de las Perlas (China).

Los autores en [143] utilizan CVA, clasificación no supervisada e interpretación visual de fotografías aéreas para detectar cambios en la cubierta terrestre y comprueban que la combinación de CVA y la clasificación no supervisada proporciona una interpretación más precisa del cambio que cualquiera de los dos métodos por sí solos. Los autores en [144] utilizan la combinación de diferenciación de imágenes y post-clasificación para detectar cambios detallados de cobertura de la tierra en el sudeste de Zambia.

Este método híbrido de detección de cambios proporciona mejor resultado que la técnica de comparación posterior a la clasificación en este escenario. El autor en [145] describe que la comparación posterior a la clasificación subestima las áreas de cambio en la cobertura terrestre.

Los autores en [146] comparan la clasificación multitemporal del TM-NDVI y el índice de humedad de diferencia normalizada NDMI para la detección del tipo de cosecha forestal y demuestran que el método RGB-NDMI produce una mayor precisión que el método RGB-NDVI.

El método ANN se utiliza para el cambio de la cobertura terrestre [147], la detección de la mortalidad forestal [36], el cambio forestal [28] y el cambio urbano [148]. Por ejemplo,

en [148] los autores aplicaron el método ANN para detectar el cambio urbano utilizando datos TM multitemporales y observan que el método basado en ANN mejora la precisión en un 20 – 30 % con respecto a la comparación posterior a la clasificación.

En resumen, los métodos de clasificación a menudo requieren una gran cantidad de datos de muestra de entrenamiento para la clasificación supervisada. La transformación de la imagen, los índices de vegetación, los métodos avanzados de clasificación, el modelado y la integración de diferentes fuentes de datos se utilizan a menudo para mejorar los resultados de la clasificación. La comparación posterior a la clasificación es un método común utilizado para la detección de cambios en la práctica, pero la dificultad para clasificar los datos de imágenes históricas a menudo afecta seriamente los resultados de la detección de cambios. El método de detección de cambios híbrido combina las ventajas del umbral y los métodos de clasificación. Los métodos de umbral, como la diferenciación de imágenes, se utilizan con frecuencia para detectar las áreas modificadas, y luego los métodos de clasificación se usan para clasificar y analizar las áreas de cambio detectadas utilizando el método de umbral. El método de detección de cambio combinado espectral-temporal y el método de detección de cambio no supervisado se utilizan con menos frecuencia en la práctica debido a la dificultad para identificar y etiquetar las trayectorias de cambio. El método EM no se usa comúnmente debido a la complejidad de estimar una probabilidad de clase conjunta. El método ANN puede proporcionar mejores resultados de detección de cambio cuando las propiedades estadísticas de la distribución de las clases de cobertura terrestre se alejan de la distribución normal. En los últimos años, la investigación sobre los métodos ANN para la detección de cambios está proporcionando resultados prometedores [28, 36, 147, 148].

La tabla 1.3 resume los tipos de métodos de detección de cambio agrupados en la categoría de Clasificación.

Tabla 1.3: Métodos de detección de cambios de la categoría Clasificación 1.2.2.3.

Método	Características	Ventajas	Desventajas	Factor clave
Comparación posterior [8, 91, 149–151]	Clasifica en mapas temáticos y compara el resultado	Minimiza efectos de sensores y atmosféricos, información completa del cambio	Costoso en tiempo y experiencia del operador	Entrenamiento de la clasificación
Análisis combinado espectro temporal [152, 153]	Combina todos los datos y clasifica y etiqueta	Simplicidad y ahorro en tiempo de clasificación	Interpretación costosa, información incompleta del cambio	Etiquetar las clases de cambio
Maximización de Expectativas (EM) [9, 94, 154–156]	Estima probabilidades de clase conjunta a partir de las imágenes	Mayor precisión de detección de cambios	Complejidad en la estima de las probabilidades	Estima la probabilidad de clase conjunta
Detección no supervisada de cambios [157–159]	Clasifica grupos de píxeles por su proximidad espectral en cada imagen e identifica cambios	Automatización del proceso	Difícil etiquetar e identificar trayectorias de cambio	Identifica grupos espectralmente similares o relativamente homogéneos

Tabla 1.3: – (Continuación métodos de detección de cambios de la categoría Clasificación 1.2.2.3.)

Método	Características	Ventajas	Desventajas	Factor clave
Detección de cambios híbrido [103, 112, 144, 160, 161]	Primero detecta el cambio, luego clasificación supervisada sobre la imagen enmascarada	Exclusión de los píxeles sin cambio	Requiere selección de umbrales, identificación de las trayectorias de cambio compleja	Selecciona umbrales y produce gran precisión
Artificial Neural Networks (ANN) [28, 36, 147, 148, 162]	Emplea redes neuronales de perceptrón multicapa para clasificar	Método paramétrico no supervisado	Complejidad, tiempo de entrenamiento y sensibilidad a la cantidad de datos de entrenamiento	Complejidad en el algoritmo y el entrenamiento

1.2.2.4 Modelos avanzados

La categoría de técnicas basadas en Modelos Avanzados incluye los modelos de mezcla espectral, los modelos de estimación de parámetros biofísicos y el modelo de reflectancia *Li-Strahler*. En estos métodos, los valores de reflectancia de la imagen a menudo se convierten a parámetros o fracciones de base física a través de modelos lineales o no lineales. Los parámetros transformados son más intuitivos para interpretar y mejor orientados a extraer información de vegetación que las firmas espectrales. La desventaja de estos métodos es el proceso lento y difícil que supone desarrollar modelos adecuados para la conversión de valores de reflectancia de imagen a parámetros biofísicos.

En esta categoría, el análisis de mezcla espectral lineal LSMA es el método más utilizado para la detección del cambio de cubierta vegetal [95], cambio de vegetación [163], cambio de área urbana [164], y cambio ambiental [165]. En el método de LSMA, la etapa crítica es la identificación de los miembros finales adecuados.

En [95] se aplica la técnica LSMA asociada a cuatro miembros finales (vegetación verde, vegetación no fotosintética, suelo y sombra) para analizar el cambio de la cubierta terrestre en la Amazonía brasileña y se comprueba que este método es mejor que los basados en clasificación tradicional. El trabajo presentado en [166] utiliza el método de LSMA para detectar los bosques talados de forma selectiva en el este de la Amazonía y se comprueba que las imágenes de la fracción del suelo derivadas de la LSMA pueden detectar con éxito las áreas afectadas por la tala selectiva. Los autores en [163] comparan los métodos multitemporales KT y LSMA para la detección del cambio de vegetación utilizando imágenes TM en el sur de California. Se demuestra que el método LSMA proporciona una precisión de detección del cambio aproximadamente un 5 % mayor que el método KT.

El método *Li-Strahler* se ha empleado para controlar la mortalidad de coníferas a través de la estimación de su cubierta de corona. Posteriormente se compara la diferencia de la cobertura de copa de cada fecha para producir los resultados de detección de cambio [35]. La ventaja de este método es la capacidad de combinar el método de procesamiento digital de imágenes con el muestreo tradicional y los métodos basados en observaciones de campo. La dificultad en la aplicación de este modelo es la recolección de suficientes mediciones de campo. Además, este modelo es relativamente complejo y no está disponible en los paquetes de software de teledetección más habituales.

Los autores en [167] demuestran que la relación entre la biomasa arbórea y la biomasa aérea total RTB es un buen parámetro biofísico para caracterizar la selva empleando datos de campo en el este de la Amazonia. El parámetro RTB refleja la estructura del rodal de vegetación y las etapas de rebrote. Se puede desarrollar a través de la integración de los datos de inventario de vegetación y las imágenes de Landsat TM. Por lo tanto, el

método de RTB se puede usar para identificar clases de vegetación. Además, las imágenes RTB temporales múltiples tienen la capacidad de detectar cambios en la vegetación después de que las diferencias de reflectancia causadas por las condiciones ambientales se calibren entre imágenes TM multitemporales. Este método se ha utilizado para la detección sucesional y madura del cambio forestal en las áreas de estudio de Altamira y Bragantina en la Amazonia brasileña [167].

Cuando se dispone de suficientes medidas de vegetación de campo, el modelo de dosel *Li-Strahler* y el modelo de estimación de parámetros biofísicos constituyen herramientas muy interesantes para la detección cuantitativa del cambio de vegetación. Sin embargo, el desarrollo de ambos modelos son costosos en tiempo y complejidad. Además, no son adecuados para la detección de cambios que no sean de vegetación.

Se demuestra que el método de LSMA es muy adecuado para la detección de cambios en la cobertura terrestre. El paso clave en la implementación de LSMA para la detección de cambios es seleccionar las clases finales adecuadas para el desarrollo de imágenes de fracciones de alta calidad y para encontrar composiciones proporcionales de cada clase de cobertura terrestre. La gran ventaja de este método es su extracción estable, fiable y repetible de información cuantitativa a nivel de sub-píxel, que brinda la posibilidad de detectar con precisión el cambio de cobertura terrestre.

La tabla 1.4 presenta los métodos del grupo de Modelos Avanzados y sus características.

Tabla 1.4: Métodos de detección de cambios de la categoría Modelos Avanzados 1.2.2.4.

Método	Características	Ventajas	Desventajas	Factor clave
<i>Li-Strahler</i>, modelo de reflectancia [35, 168, 169]	Estima cubierta de corona de pie de conífera y compara	Resultados estadísticos y mapas completos	Requiere medición de campo, complejidad, adecuado solo para vegetación	Estudia la corona de la vegetación
Modelo de mezcla espectral [95, 124, 163, 170–173]	Deriva imágenes de fracción de clase y compara	Las fracciones tienen significados biofísicos, resultados son estables, precisos y repetibles	Análisis complejo	Identifica miembros finales, escoge umbrales
Método de parámetros biofísicos [167, 174, 175]	Modelo de estimación de parámetros biofísicos a partir de medidas de campo y datos de teledetección y compara	Detectar con precisión el cambio de vegetación en función de las estructuras físicas de la vegetación	Complejidad para desarrollar el modelo y corregir efectos atmosféricos y ambientales, muchas medidas de campo, es útil solo para vegetación	Estimación de parámetros biofísicos y asociación con cada clase

1.2.2.5 Métodos basados en SIG

La categoría de detección de cambios basada en SIG incluye el método SIG integrado con teledetección y el método SIG puro. La ventaja de usar SIG es la capacidad de incorporar datos de diferente origen. Sin embargo, esta integración de datos con diferentes resoluciones y características puede afectar negativamente a los resultados finales.

Los autores en [176] utilizan un método SIG para evaluar el impacto del desarrollo de nuevas ciudades en Hong Kong, mediante la integración de datos fotográficos aéreos multitemporales del uso del suelo. Demuestran que las técnicas de superposición de imágenes y enmascaramiento binario son útiles para hallar el cambio de forma cuantitativa. En los últimos años, la incorporación de datos de múltiples fuentes (por ejemplo, fotografías aéreas, TM, SPOT y mapas temáticos previos) resulta atractiva debido a la gran cantidad de datos disponibles y a la capacidad creciente de procesado y se ha empleado en la detección de cambios en el uso de la tierra y el suelo LULC [14, 24, 27, 61, 70, 71, 97, 177, 178]. Esta necesidad de tratar datos de distinto origen se hace mayor cuando la detección de cambios involucra intervalos de períodos largos asociados con diferentes fuentes históricas de datos en cuanto a formatos o resoluciones [97].

El autor en [14] utiliza la integración de teledetección, SIG y modelos estocásticos para detectar cambios en el uso de la superficie terrestre en el delta de Zhujiang de China e indica que dicha integración es un método eficaz para analizar la dirección, el tipo y el patrón espacial del cambio de uso de la tierra.

Los autores en [179] utilizan un método de clasificación no supervisado, reclasificación espacial de imágenes basada en SIG y comparación posterior a la clasificación con superposición SIG para cartografiar el suelo urbano y su dinámica en el área metropolitana de Atlanta (Georgia, EEUU).

Así, en los casos mencionados, los métodos SIG han demostrado ventajas sobre los métodos de detección de cambios tradicionales en el análisis de datos de múltiples fuentes. La mayor parte de las aplicaciones presentadas se centran en las áreas urbanas. Esto se debe probablemente a que los métodos tradicionales a menudo presentan dificultades en la integración de datos auxiliares tales como datos de catastro y datos geoespaciales, que en entorno urbano son abundantes. Sin embargo, se necesita más investigación centrada en la integración de SIG y otras técnicas de teledetección tradicionales para mejorar los resultados finales en entornos no urbanos.

La tabla 1.5 resume las características de los métodos basados en SIG.

1.2.2.6 Métodos basados en Análisis Visual

La categoría de métodos basados en Análisis Visual incluye la interpretación visual del compuesto de imagen multitemporal y la digitalización en pantalla de áreas modificadas. Este método puede hacer un uso completo de la experiencia y el conocimiento de un analista. La textura, forma, tamaño y los patrones de las imágenes son elementos clave en la identificación del cambio LULC a través de la interpretación visual. Estos elementos no se suelen utilizar en otros métodos debido a su dificultad de extracción. Sin embargo, en la interpretación visual, un analista experto puede incorporarlos para ayudar a tomar decisiones sobre el cambio de LULC. La clara desventaja de este método es el tiempo consumido para analizar un área extensa y su dificultad para proporcionar resultados de trayectorias de cambio detalladas.

La interpretación visual se utilizó ampliamente en diferentes campos, como el inventario forestal, antes de la década de 1970. En aquella época, no había prácticamente datos de satélite ni capacidad de computación. Con el desarrollo de las tecnologías de procesadores y las técnicas de teledetección, el procesamiento digital reemplazó gradualmente la interpretación visual. Sin embargo, el procesamiento automático de imágenes para eventos localizados y críticos suele recurrir a este tipo de metodología. Por ejemplo, la detección de la tala en el bosque suele ser muy difícil de rastrear de forma automática y un operador experto producirá mejores resultados [180]. Los autores en [181] utilizan la interpretación visual en datos MSS, TM y *Enhanced Thematic Mapper Plus (ETM+)* para detectar cambios en la cobertura terrestre de los Estados Unidos y estimar las precisiones de cambio. La interpretación visual en mayor o menor medida se emplea al inicio de un estudio para analizar cualitativamente la cobertura terrestre y seleccionar los métodos semiautomáticos más adecuados. También se suele emplear para el entrenamiento de procesos supervisados y en la validación de resultados.

La tabla 1.6 resume las características de esta categoría.

Tabla 1.5: Métodos de detección de cambios de la categoría SIG 1.2.2.5.

Método	Características	Ventajas	Desventajas	Factor clave
Método SIG integrado con teledetección [14, 24, 33, 61, 70, 71, 177, 178]	Integra a la vez imágenes de teledetección y capas SIG para un análisis posterior	Analiza datos auxiliares para facilitar la interpretación y facilita la exportación de resultados	Datos de distintas fuentes pueden degradar los resultados	Necesita gran precisión en el registro de las fuentes de datos

Tabla 1.6: Métodos de detección de cambios de la categoría Análisis Visual 1.2.2.6.

Método	Características	Ventajas	Desventajas	Factor clave
Interpretación visual [19, 133, 180, 183, 184]	Selecciona por cada banda RGB una imagen de tres fechas distintas e interpreta visualmente el compuesto de color	La experiencia y el reconocimiento humano	Resultados dependen de la habilidad del analista, tiempo y dificultad para actualizar los resultados	Habilidad del analista y familiaridad con el área de estudio

1.2.2.7 Otras técnicas de detección de cambios

Además de las seis categorías de técnicas de detección de cambios discutidas anteriormente, también existen otros métodos que no pertenecen a ninguna de ellas y aunque son interesantes no se han desarrollado más por la comunidad científica. Por ejemplo, en [185] se emplea medidas de dependencia espacial con datos de TM para detectar cambios en tierras de pasto.

En [186] se utiliza un sistema de visión artificial para detectar cambios en la cobertura terrestre en las franjas urbanas. Los autores en [104] utilizan tres indicadores: índice de vegetación, temperatura de la superficie terrestre y estructura espacial, derivados de AVHRR, para detectar cambios en la cobertura del suelo en el oeste de África.

En [187] se emplean curvas de cambio y en [11] se utilizan modelos lineales generalizados para detectar cambios en la cobertura terrestre. También los autores en [188] utilizan la densidad del camino y la información espectral TM para generar métodos basados en la diferenciación de imágenes espectrales-estructurales para detectar el cambio de la tierra urbana en Pekín (China).

Los autores en [189] usan un modelo de campo aleatorio condicional para detectar los cambios de la cobertura terrestre. Mientras que, en [190], se usa la transformada de Radon y la divergencia de Jeffrey para detectar cambios en las imágenes SAR multitemporales.

1.2.3 Estudio comparativo de técnicas de detección de cambios

Esta sección compara de forma cuantitativa la precisión asociada con diferentes técnicas de detección de cambios. En general, las técnicas de detección de cambios se pueden agrupar en dos tipos: (1) las que detectan información binaria de cambio/no-cambio, por ejemplo, usando diferenciación de imagen, relación de imagen, diferenciación de índice de vegetación y la transformada PCA, y (2) aquellas que detectan cambios detallados “desde-a”, por ejemplo usando la comparación posterior a la clasificación, la técnica CVA y los métodos híbridos. El paso crítico en el primer caso (cambio/no-cambio) es seleccionar valores de umbral apropiados en las colas del histograma que representa la información de cambio detallados en el apartado 1.2.4. Sin embargo, en la detección de cambios detallada “desde-a”, la clave es crear imágenes de clasificación temáticas precisas. Los errores de las imágenes temáticas de fechas individuales afectarán la precisión de detección de cambios finales.

En la práctica, el operador humano suele seleccionar varios métodos de detección de cambios en un área de estudio, para más tarde identificar al que proporciona mejores resultados de precisión para esa zona de interés. Los autores en [120] examinan varios métodos para detectar la defoliación, tales como la transformada PCA, la diferenciación

de imágenes, la clasificación y la comparación posterior a la clasificación. Así, se encuentra que la clasificación de los componentes principales y las imágenes de diferencia proporcionan mejores precisiones. La precisión total varía desde el 61 % (post-clasificación) y 63 % (PCA) al 69 % (diferenciación de imágenes) comparando con datos de campo medidos de forma aérea para monitorización de la defoliación.

El autor en [149] compara seis métodos de diferenciación de imágenes, diferenciación de índices de vegetación, PCA selectiva, clasificación directa sin supervisión temporal, diferenciación de cambios post-clasificación, y una combinación de mejora de imagen y comparación posterior a la clasificación, en una zona costera del estado de Campeche (México). Concluye que la comparación posterior a la clasificación es el procedimiento más preciso y presenta la ventaja de indicar la naturaleza del cambio. La precisión global para el nivel de cambio/no-cambio varía del 73 % al 87 %.

Los autores en [103] comparan la clasificación posterior, la diferenciación de imágenes y la técnica PCA para determinar el cambio en las praderas de pastos marinos usando los datos de Landsat TM. Los datos de referencia se recogen de fotografías aéreas, combinadas con una campaña de datos tomada desde embarcaciones. Se utiliza una matriz de error para evaluar cuantitativamente la precisión. Se encuentra que la técnica de diferenciación de imágenes ofrece un rendimiento significativamente mejor que la comparación de clasificación posterior y la técnica PCA, siendo la precisión global para la matriz de error de cambio/no-cambio del 78 %.

Los autores en [191] evalúan cinco técnicas de detección de cambios no supervisadas utilizando datos de SPOT *High-Resolution Visible (HRV)* multispectrales y multitemporales para identificar la respuesta de la vegetación de un ecosistema forestal a inundaciones extensas asociadas con la tormenta tropical Alberto. Las técnicas estudiadas son clasificación de cambio espectral-temporal, clasificación de cambio temporal basada en NDVI, PCA de datos espectrales, PCA de datos NDVI, y diferenciación de imágenes NDVI. Se utilizan técnicas estadísticas estándar, regresión múltiple logística y un modelo de vector de probabilidad para evaluar cuantitativamente y visualmente la precisión de la clasificación. Se comprueba que la precisión de la clasificación mejora cuando se usa la clasificación de cambio temporal basada en datos NDVI. Ambos métodos de PCA son más sensibles a la vegetación afectada por las inundaciones que las clasificaciones de cambio temporal basadas en datos espectrales y NDVI. Los cambios en la vegetación se identifican con mayor precisión mediante la diferenciación de imágenes de los datos NDVI (la precisión general es del 77 %).

Los autores en [93] analizan comparación de imágenes, división de imágenes, PCA y comparación post-clasificación asociada con diferentes métodos de normalización de imagen incluyendo conjunto oscuro y brillante, características pseudo invariantes y regresión

controlada automáticamente del diagrama de dispersión. Se demuestra que la regresión controlada automatizada del diagrama de dispersión entre diferenciación de imagen normalizada y la diferenciación NDVI proporciona los mejores resultados de detección de cambio/no-cambio.

Los autores en [192] comparan la diferenciación de imágenes, PCA y CVA para la detección de áreas asociadas con inundaciones y erosión usando datos de TM multitemporales en la región central de Nepal. Encuentran que CVA proporciona una alta concordancia espacial (88 %) en las categorías de cambio/no-cambio.

En resumen, aunque se han implementado en la literatura un gran número de técnicas de detección de cambios, la conclusión sobre qué método es el más adecuado en una zona específica sigue sin respuesta. Es más, en los trabajos comentados anteriormente, cada problema se resuelve mejor mediante una técnica diferente. Así, el método seleccionado dependerá del conocimiento del analista sobre las técnicas existentes y su habilidad para manejar los datos de teledetección conforme a las características del área de estudio. Los trabajos anteriores han demostrado que una combinación de dos técnicas de detección de cambios, tales como diferenciación de imágenes y PCA, NDVI y PCA, o PCA y CVA, suelen mejorar los resultados finales. Los métodos que se aplican más a menudo son la diferenciación de imágenes, la transformada PCA, el método CVA y la comparación posterior a la clasificación. Por ello, en esta Tesis se toman como punto de partida el método CVA, la comparación posterior a la clasificación, y la interpretación visual.

1.2.4 Revisión de trabajos relacionados con la selección de umbral

Muchos algoritmos de detección de cambios, como los pertenecientes a las categorías de álgebra y transformación, requieren la selección de umbrales para diferenciar el cambio/no-cambio [1]. Básicamente existen dos estrategias para la selección de umbral [1, 30, 99, 193]:

- Procedimiento empírico o de prueba y error. Un operador humano ajusta de forma interactiva los umbrales y evalúa la imagen resultante hasta que esté satisfecho. Este método requiere un analista experimentado mucho tiempo para su implementación [194].
- Medidas estadísticas. Se ajusta el umbral a la desviación estándar y la media de cada clase [1].

Las dos desventajas principales de las técnicas de umbral son:

- La influencia de factores externos causados por condiciones atmosféricas, la iluminación, la humedad de suelo y las diferencias fonológicas.

- El hecho de que el umbral seleccionado es subjetivo y dependiente de la escena y de la habilidad del analista.

Para mejorar los resultados de detección de cambios, el autor en [96] utiliza el conjunto *Fuzzy* y sus funciones para reemplazar los umbrales clásicos. Los autores en [194] proponen un análisis automático basado en la teoría de Bayes para conseguir un error mínimo, y una técnica de coste mínimo para determinar el umbral que minimiza la probabilidad de error de detección de cambio general.

En [99], los autores desarrollan el método DFPS, que permite determinar el umbral de magnitud del cambio. Este método se basa en seleccionar un umbral de entre muestras de entrenamiento que contienen todos los posibles tipos de cambios.

En [195] los autores analizan el rendimiento de diferentes técnicas de determinación de umbral para el análisis vectorial de cambio y concluyen que el método semiautomático DFPS supera de manera efectiva los límites de precisión de las técnicas de determinación manual.

Aunque se han desarrollado algunos métodos muy avanzados para mejorar los resultados de detección de cambios que no requieren selección de umbral [96, 99, 194], estos se utilizan con menos frecuencia en la práctica debido a su complejidad. Sin embargo, debido a la simplicidad, los métodos basados en selección de umbral siguen siendo los más ampliamente aplicados pese a las desventajas anteriormente comentadas.

1.2.5 Revisión de trabajos relacionados con la selección de datos

Se suelen escoger datos de resolución moderada tales como TM, SPOT y radar cuando se realizan estudios a nivel regional. En contraposición, los datos de resolución baja son útiles para estudios de zonas más amplias ya que en ese caso bajan los requerimientos en resolución espacial.

Las ventajas de la disponibilidad diaria de datos de bajo coste de AVHRR (*National Oceanic and Atmospheric Administration (NOAA)*) lo convierten en la mejor fuente de datos espectrales para la detección de cambios en áreas extensas. Por ejemplo, se ha utilizado AVHRR para detectar cambios en la cobertura del suelo en el oeste de África [104], en la detección y eliminación de nubes [196, 197], para mapear la regeneración de bosque tropical [41], en monitorización de inundaciones [87], en detección automática de humo de fuego usando redes neuronales artificiales [198], detección automática de estructuras de mesoescala oceánicas [199] y estudio de la distribución de la cobertura de nieve [200].

Los datos MODIS también han empleado en aplicaciones prometedoras en la detección de cambios LULC. Los autores en [12] implementan productos de cambio de cobertura terrestre utilizando datos MODIS de resolución de 250 m, y deforestación en el sur de

Brasil [201]. También se usan para detección de incendios en bosques en [202, 203]. Los índices de vegetación tales como el NDVI y la temperatura de la superficie terrestre derivada de las bandas térmicas de AVHRR o MODIS son útiles para la detección de grandes cambios de área.

Los datos Landsat han sido empleados en muchos estudios, destacando los siguientes trabajos: detección con vectores de cambio en bosques de Abeto Picea [122], detección de cambios en series secuenciales de Landsat [13], monitorización de grandes áreas de bosques [28, 29, 54, 146, 169], detección de cambios en áreas urbanas [188, 204], detección de desertificación [46, 48, 84, 124, 205] y detección de incendios de bosques [203].

Los datos del programa SPOT se han empleado en diferentes estudios: para la monitorización de zonas urbanas [69], en detección de cambios en humedales [206] y en detección de cambios general [4, 18]. También se han empleado para la evaluación de la temperatura de la superficie terrestre en zonas urbanas [207], y en [208] se usan las imágenes de SPOT para detección de cambios usando el método de similitud de tendencia de espectro.

Las imágenes SAR son una alternativa a los productos ópticos multiespectrales tradicionales. Hoy en día existen cada vez más oportunidades de acceder a este tipo de imágenes en distintas bandas de trabajo, polarizaciones y resoluciones espaciales. Por ello, recientemente se ha introducido en distintos estudios y en diferentes áreas, por ejemplo: para detección de humedales costeros [81], para detección y monitorización del balance de los glaciares [89], para detección de casas aisladas [160], para detección de cambios en zonas urbanas [75, 76, 209], y para detectar campos de refugiados mediante fusión de imágenes ópticas y SAR [210].

Los datos multiespectrales de Landsat y SPOT se han convertido en una importante fuente científica de datos de satélites de alta resolución espacial y las imágenes SAR aportan valiosa información, aunque difícil de integrar con los otros datos. Debido a ello, en esta Tesis se aborda esta problemática, que cada vez tiene más interés tal y como se desprende de la investigación científico-técnica actual.

1.2.6 Revisión de trabajos relacionados con la evaluación de precisión

La evaluación de la precisión es muy importante al utilizar los resultados para la toma de decisiones. Los elementos de evaluación de precisión más comunes incluyen la precisión global, la precisión del productor, la precisión del usuario y el coeficiente kappa. La literatura previa ha tratado este tema ampliamente [211–220].

Los autores en [214, 215, 218, 219] revisan la evaluación de precisión para la clasificación de fecha única y discuten algunos temas específicos relacionados con la evaluación

de precisión. Los autores del libro en [220] analizan de forma sistemática los conceptos de evaluación básica de la precisión además de algunos temas avanzados relacionados con la lógica *Fuzzy* y la evaluación multi-capa, y explican los principios y consideraciones prácticas del diseño y la evaluación de la precisión de los datos de teledetección. En particular, este libro muestra el diseño de muestreo, la recopilación de datos, el desarrollo y el análisis de una matriz de error y proporciona un estudio de caso para evaluar la precisión de los datos de teledetección de fecha única.

La evaluación de la precisión en detección de cambios es particularmente compleja debido a las dificultades que aparecen en la recopilación de conjuntos de datos fiables a lo largo del tiempo. Por lo tanto, muchas investigaciones previas no proporcionan un análisis cuantitativo de la calidad de los resultados. Aunque las técnicas de evaluación de precisión estándar se desarrollan principalmente para datos de teledetección de una sola fecha, el método de evaluación de la precisión basado en la matriz de confusión sigue siendo interesante para la evaluación de los resultados de detección de cambio.

También se han desarrollado algunos métodos específicos para analizar la precisión de la detección de cambios multitemporal [221, 222]. Los autores en [221] utilizan curvas de evaluación de precisión con imagen satelital, y [222] desarrolla un método de evaluación de precisión basado en áreas para el análisis de mapas de cambio.

En el libro [217], el autor se centra específicamente en la evaluación de la precisión de la detección de cambios en la cobertura terrestre. Este libro describe los problemas, identifica los factores que afectan a la evaluación de precisión y presenta un diseño de muestreo para estimar los elementos de la matriz de confusión de manera eficiente. Por último, señala posibles aplicaciones y brinda recomendaciones para la evaluación de precisión.

La matriz de confusión es el método más común para la evaluación de la precisión. También se usan otros elementos importantes derivados de ella, tales como la precisión global, los errores de omisión, los errores de comisión y el coeficiente KHAT (coeficiente kappa) [99, 101, 193, 211, 220, 223–225].

En detección de cambio, a menudo se emplean unos índices que representan distintos tipos de cambio para cada clase: ganancia, pérdida, cambio total, índice de intercambio, valor absoluto del cambio neto, y que están definidos en [226]. Otros índices relacionados con la clase que representa contenido de agua tales como la diferencia normalizada del agua y el índice de diferencia normalizada de sequía se han desarrollado al efecto en [227, 228]. En cuanto al desarrollo de nuevos índices, la evaluación de su precisión se debe considerar con detenimiento a la hora de la extracción de conclusiones.

1.3 Organización de la tesis

La tesis se divide en seis capítulos y un apéndice. En este primer capítulo se presenta una visión general del tema desarrollado en el marco de esta Tesis y los objetivos que quiere alcanzar. El estado del arte se ha dividido en seis secciones. La primera muestra una revisión sobre las consideraciones generales para la teledetección. La segunda sección proporciona una revisión general de las técnicas actualmente utilizadas para la detección de cambios. Luego, se presenta un estudio comparativo de las soluciones existentes. En la cuarta sección se explica los métodos de selección de umbral desde el punto de vista de la literatura. Después se revisa las contribuciones según la selección de datos, el área de estudio y la problemática estudiada. Por último, se revisan los trabajos según los elementos de evaluación de precisión de los resultados de detección de cambios que aportan. Todo esto proporciona una buena perspectiva sobre la importancia estratégica de la rama de la teledetección y sus aplicaciones en el contexto de las imágenes de satélite. Pasando a la estructura, el trabajo de esta Tesis doctoral se divide de la siguiente manera:

Capítulo 2 El segundo capítulo está dedicado a la descripción del contexto del problema que se aborda. Así, se introduce el tema de los desastres ambientales y sus relaciones con la teledetección. También se describen los tipos de imágenes de satélite y sus características, y se resumen las diferentes misiones de teledetección. El objetivo principal de este capítulo es la descripción de los desastres y su relación con la teledetección.

Capítulo 3 En el tercer capítulo se presentan las principales metodologías básicas de detección de cambios. Se describen los tipos de correcciones, el concepto de las clasificaciones por píxel y por objeto, y por último las herramientas de evaluación de cambio (matrices de cambio, matriz de transición y los índices de cambios).

Capítulo 4 En este capítulo se presentan las áreas de estudio de China y Argelia. Se selecciona el mejor clasificador por píxel. Se usan las técnicas de detección de cambios CVA y la interpretación visual. Se emplea el método DFPS para la búsqueda del umbral óptimo. Todo esto se emplea para evaluar los cambios en una zona muy dinámica y otra con poco cambio. Finalmente se comparan los resultados mediante las herramientas de evaluación y las matrices de transición.

Capítulo 5 Se describen los diferentes programas para la lucha contra la desertificación en Argelia. Se presenta la zona estudiada y sus variaciones ambientales. Se desarrolla la metodología de detección de cambio comparando diferentes tipos de clasificación por píxeles y por objetos. También se compara la detección de cambio con vectores y la comparación posterior a la clasificación de los datos ópticos, ya que se discrimina

el cambio en un periodo de 25 años. Además se desarrolla una nueva metodología para la fusión de los datos radar en sus distintas polarizaciones con los datos ópticos, para añadir más información, y mejorar la clasificación y la detección de cambios. Por último se comparan los resultados de las metodologías propuestas.

Capítulo 6 Este capítulo resume las principales conclusiones de este trabajo. Asimismo, describe las líneas potenciales de investigación y desarrollo asociadas con el trabajo realizado en el marco de esta Tesis, y se definen las futuras líneas de investigación.

Apéndice A En este apéndice se aportan las publicaciones científicas publicadas a lo largo del desarrollo de esta Tesis.

Degradación medioambiental y teledetección

Las imágenes de satélite y las técnicas de teledetección permiten analizar las causas y las consecuencias de la degradación en el medio ambiente. Este capítulo presenta diferentes escenarios de desastre natural o humano, junto con los daños asociados y su posible evaluación. La teledetección es particularmente interesante en este escenario, debido a su capacidad de recopilar información a gran escala.

Aquí se describen algunos tipos de degradación medioambiental, haciendo hincapié en la desertificación. Cuando surge un desastre medioambiental, se puede monitorizar la situación de forma directa in situ o mediante teledetección. Este último es uno de los principales recursos de los que se dispone actualmente para estudiar el cambio en el medio que nos rodea. La teledetección se refiere al proceso mediante el cual se obtiene información de un objeto, área o fenómeno sin contacto directo con el mismo. Con los avances tecnológicos actuales y con la preocupación creciente por el medio que nos rodea, la teledetección hoy en día es una técnica multidisciplinar que proporciona recursos muy útiles en distintos ámbitos.

2.1 Desastres naturales y de origen humano

La definición formal de un desastre natural es la aparición de un fenómeno natural de una intensidad anormal que resulta en graves daños materiales, cuando los medios usuales para evitar dicho daño no se emplearon o no fueron efectivos. Un desastre natural es un concepto reconocido administrativamente y jurídicamente para describir un fenómeno de la naturaleza. Estos desastres naturales pueden estar relacionados con: terremotos, inun-

daciones o tsunamis, incendios, erupciones volcánicas, tormentas u otras inclemencias del tiempo, deslizamientos de tierra, sequías, olas de calor, tormentas de nieve o avalanchas, cambio climático o desertificación, que será el objeto de nuestro interés. En algunos de estos fenómenos también influye el factor humano en menor medida.

Los desastres de origen humano también son de naturaleza diversa. Se puede clasificar en tres amplias categorías por su origen: desastres industriales tales como explosiones o vertidos contaminantes, accidentes en los medios de transporte (aire, mar o tierra) y las intervenciones militares tales como bombardeos.

2.1.1 Daños provocados por desastres naturales

El daño causado por un desastre natural varía según el tipo de desastre y pueden afectar al medio ambiente natural y también a distintas actividades humanas que se desarrollen en la zona.

En el caso de un terremoto, las pérdidas observadas suelen afectar a las construcciones humanas. De hecho “La mayoría de los efectos sobre el medio ambiente natural dependen de sus características geomorfológicas e hidrológicas y son difíciles o incluso imposibles de evaluar por un observador” [229] (caída de rocas, grietas en la tierra). Las pérdidas en los edificios pueden resultar en grietas más o menos severas, desprendimientos, o incluso la destrucción total del edificio.

En el caso de maremotos, tsunamis, inundaciones o deslizamientos de lodo, las pérdidas causadas son diferentes de las anteriores. Las estructuras a menudo tienen un comportamiento binario. O bien se desvanecen por completo o se resisten y no muestran desde el exterior muchos signos de daño. En los desastres relacionados con el agua, hay una gran cantidad de escombros y otros objetos que son arrastrados por el agua. En estos casos, existe un límite que separa el área afectada del área intacta. Un análisis de daños basado en la determinación de estos límites se muestra en [230].

En el caso de tormentas, tornados o ciclones, los tejados o estructuras altas se suelen desprender. El resto de elementos en la mayoría de los casos quedan indemnes. El análisis del estado de los tejados es así un buen indicador del daño en este caso.

En el caso de la desertificación, el cambio gradual está causado por el movimiento de arena y no se aprecia bien hasta que se una cantidad considerable de arena desplazada a otra área donde antes había vegetación, zona urbana, o suelo desnudo.

2.1.2 Cuantificación del cambio

El cambio causado por un desastre mayor se puede analizar directamente enviando un equipo humano al sitio, o mediante una observación remota mediante teledetección (sensores aéreos o espaciales). Las observaciones directas sobre el terreno requieren una buena planificación y disponibilidad temporal. Además, el acceso a ciertos lugares puede estar restringido por razones políticas, económicas o prácticas.

El análisis visual de imágenes adquiridas por teledetección es la solución más empleada hoy en día para la creación de mapas de cambio. La teledetección permite obtener información de grandes zonas (cientos o miles de km²) en una sola adquisición. Además, esta información no depende de las infraestructuras ni de las autoridades locales. Actualmente, las imágenes de crisis y los mapas de daños se generan por parte de organizaciones como *National Aeronautics and Space Administration (NASA)*, *ESA*, *Japan Aerospace Exploration Agency (JAXA)*, *Deutsches Zentrum für Luft- und Raumfahrt (Centro Aeroespacial Alemán) (DLR)*, *SErvice Régional de Traitement d'Image et de Télédétection (SERTIT)*, o *UNITAR's Operational Satellite Applications Programme (UNOSAT)*. SERTIT (Estrasburgo, Francia) es un organismo francés responsable de extraer y dar formato a la información de observación de la Tierra. El DLR es la agencia espacial alemana, que también tiene una unidad de asistencia en la gestión de grandes crisis. Finalmente, UNOSAT depende de las Naciones Unidas y su función es permitir que la comunidad tenga acceso a imágenes satelitales y SIG. Las imágenes posteriores al desastre se examinan visualmente, en particular en las zonas urbanas, y se delimitan áreas con diversos grados de daño.

El primer paso en las técnicas basadas en teledetección es la obtención de datos. Es necesario tener datos lo más rápido posible para preparar los mapas de cambio. En la Carta Internacional “Espacio y Grandes Desastres” [231], se describe que el tiempo promedio entre el evento y la adquisición de imágenes de crisis es cercano a 5 días. Es necesario elegir el satélite más adecuado (longitud de onda, resolución, disponibilidad) y programar las adquisiciones, que en algún caso requiere hasta 25 horas de anticipación [232]. Entonces, se descargan los datos y se procesan. Una vez que se inicia este proceso, es posible sistematizar la monitorización diaria de la situación. Debido al gran volumen de datos generados, es difícil tratarlos visualmente. Así, una imagen SPOT-5 de MAR (resolución de 2,5 m, con un área de 60 km por 60 km) requiere la visualización sucesiva de al menos 600 ventanas de 1000 por 1000 píxeles [232]. Por ello, se necesitan herramientas de extracción de información automáticas robustas y rápidas para acelerar el acceso a la información crítica.

La resolución espacial y espectral de las imágenes utilizadas es crucial. Es importante disponer de información de varios sensores en distintas resoluciones y diferentes longitudes

de onda, aunque sean redundantes. Por ejemplo, se pueden utilizar datos de SPOT-5 o Landsat, que tienen respectivamente una resolución espacial de 5 m y 30 m. Esta resolución permite una descripción a gran escala, pero no permite una descripción del daño con detalle en áreas urbanas. Por ello, los datos MAR se utilizan cada vez más, a medida que se hacen más accesibles. Las malas condiciones climáticas también pueden ser un obstáculo para el análisis de datos en el espectro óptico. En este caso, las imágenes radar presentan una gran ventaja al operar en casi cualquier condición atmosférica, en contrapartida su análisis visual suele requerir más conocimientos para el operador que en el caso de imágenes ópticas.

Por último, la fiabilidad del mapa de cambio realizado es esencial desde el punto de vista del rescate, pero para el operador no siempre es fácil decidir con certeza el estado de los edificios o una infraestructura. El análisis visual siempre deja una parte a la subjetividad. Sin embargo, es necesario poder discriminar el daño de los cambios naturales o sin interés, con la mejor fiabilidad. Las escalas de daños empleadas por diferentes organismos de teledetección permiten el intercambio ágil de información entre ellos. Algunos desastres como incendios o de actividad volcánica se cuantifican con una decisión binaria. En otros casos se puede distinguir más niveles de afectación.

2.1.3 Caso de estudio: desertificación

“La desertificación es el proceso de degradación de la tierra que afecta a zonas áridas, semiáridas y subhúmedas secas, causado por diferentes factores, entre ellos el cambio climático y la actividad humana” [233]. Ésta definición formal de desertificación es la acordada por la UNCCD en París el 17 de junio de 1994. Esta fecha conmemora desde entonces el día mundial de la lucha contra la desertificación y la sequía. En esta descripción intervienen diversos conceptos que tienen especial importancia para la comprensión del fenómeno de la desertificación, según el Programa de Naciones Unidas para el Medio Ambiente (PNUMA) y UNCCD [233]:

- Tierra: constituye el sistema bioproductivo terrestre que contiene la orografía del suelo, los bosques, vegetación no densa, otros elementos bióticos y los ciclos hidrológicos y ecológicos en el marco del sistema climático.
- Áreas áridas, semiáridas y subhúmedas secas: son aquellas áreas en que la relación entre la evaporación, transpiración y la precipitación anual está incluida en el intervalo 0,05 y 0,65, con la excepción las áreas polares y sub-polares.
- Sequía: es la anomalía que se registra cuando falta el agua de lluvia o de reserva, superficial o subterránea o bien cuando se producen lluvias con niveles más bajos



Figura 2.1: Avance de desertificación en el Desierto. **Fuente:** Tim White, n.d.

de lo normal. Esta anomalía, causada por el desequilibrio climatológico, degrada los sistemas de producción.

- Degradación de la tierra: se refiere a la merma en el rendimiento, el cambio en los ciclos biológicos y la pérdida económica de las zonas agrícolas y de pasto. Esta degradación principalmente reduce la vegetación.

La desertificación es un fenómeno socioeconómico y ambiental que afecta a nivel internacional, que requiere una vigilancia especial, y que actúa a largo plazo [233, 234]. Afecta en áreas especialmente áridas y causa efectos muy negativos en la cubierta del suelo, principalmente falta de agua y de vegetación. Algunos factores que influyen en el avance de la desertificación son: abandono de áreas agrícolas, deforestación, movimiento de dunas y contaminación del aire, agua y suelo.

Para combatir la desertificación, muchos países y organizaciones nacionales e internacionales han implementado diferentes proyectos e ideas, pero el problema dista mucho de estar resuelto y quizás no se llegue nunca a resolver [233]. La figura 2.1 muestra el avance de desertificación en las inmediaciones del Desierto del Sahara. En el caso de Argelia la desertificación afecta a muchas ciudades cercanas al desierto del Sahara, que ocupa el 87 % de su territorio. De 238 millones de hectáreas, 207 millones se sitúan en el Sahara y el resto en zonas muy frágiles que bien están comprometidas en el proceso de desertificación o bien están en la costa mediterránea. De entre las ciudades especialmente sensibles a la desertificación, podemos destacar: Djelfa, Tiaret, Laghouat y M'sila en el centro, Batna, Khenchela, Tébessa y Biskra en el este, Nâama, El Bayadh, Saida y Tlemcen en el oeste.

2.2 Observación de la tierra por satélite

Hoy en día, las imágenes de satélite constituyen una fuente de información muy importante en varios campos, como el urbanismo, la planificación de territorios, la cartografía, la evolución de la vegetación y otros muchos. Además, cada vez existen más sensores en más bandas y resoluciones. Esta gran disponibilidad bajo política de datos abiertos es el germen de este trabajo de investigación para la detección de cambios.

Las imágenes obtenidas desde satélite presentan varias ventajas en comparación con otros medios como la fotografía aérea, estudios de campo o mapas. En primer lugar, se producen adquisiciones repetibles en las mismas condiciones de iluminación y en formato digital, que permite su procesado automático. Las observaciones tienen carácter global y se puede acceder a archivos históricos que permiten una evaluación a largo plazo de la dinámica terrestre. Además, cada vez existen más sensores con más bandas y resoluciones, que recogen datos de forma sistemática o bajo solicitud. En esta sección se presentan diferentes aspectos relacionados con las imágenes de satélite, tales como: tipos de imágenes, el concepto de la resolución y las misiones más interesantes para el estudio de la degradación del medio ambiente.

2.2.1 Tipos de imágenes satelitales

Las imágenes de satélite se pueden clasificar de acuerdo con el número de bandas espectrales y la naturaleza de los sensores con los cuales fueron adquiridas. Distinguiremos imágenes pancromáticas, multiespectrales, hiperespectrales, de múltiples sensores e imágenes de radar.

- **Imágenes pancromáticas:** se obtienen a partir del registro de la radiación en el visible en un rango de longitud de onda comprendido aproximadamente entre 0,4 y 0,7 μm [235–237]. Aunque estas imágenes son menos ricas desde el punto de vista de la resolución espectral, ofrecen una resolución espacial muy buena. En las imágenes de MAR, el efecto de paralaje es difícil de corregir con los métodos de corrección geométrica utilizados habitualmente para imágenes de resolución media. En particular, una ortorectificación apropiada requiere un DEM muy preciso, que en ocasiones no está disponible. Los cambios rápidos en altura producidos por ejemplo por un edificio en un entorno montañoso no se pueden compensar con un Modelo Digital de Terreno (MDT) de resolución media. Estos efectos se acentúan a medida que el ángulo de elevación del satélite con respecto al horizonte baja. Las imágenes multiespectrales aumentan el número de bandas espectrales a costa de empeorar la resolución espacial con respecto a las imágenes pancromáticas. Sin embargo, se puede fusionar una imagen multiespectral con una imagen pancromática simultánea,

y así obtener una imagen “*pansharpened*” en varias bandas con una resolución muy alta. Existen diversos métodos de fusión de imágenes en la literatura [74, 236–238]. Estas técnicas pueden clasificarse en tres categorías [238]: técnicas de proyección y sustitución, las basadas en la contribución espectral relativa y las relacionadas con el concepto *Agricultural Remote Sensing Information System (ARSIS)*. Entre los últimos métodos, cabe mencionar la transformada *Wavelet* (algoritmo de Mallat y algoritmo de agujero).

- **Imágenes multiespectrales o multibanda:** se obtienen a partir de un conjunto de bandas espectrales correspondientes a diferentes rangos de longitudes de onda, cuyo número máximo de bandas no suele exceder de diez. La figura 2.2 representa una imagen óptica del satélite SPOT tomada el 11 de junio 2012 en Argel (Argelia). Tradicionalmente, en un marco operativo para el análisis de imágenes, los datos más utilizados están en el dominio visible y el infrarrojo por dos razones principales. Por un lado, las imágenes en el espectro visible son fácilmente interpretables porque trabajan en la misma región espectral que el sistema humano de visión. Por otro lado, la tecnología existente permite obtener muy buenas resoluciones espaciales en estas regiones del espectro. Sin embargo, las condiciones atmosféricas pueden presentar graves problemas en la adquisición de datos. La presencia de nubes, niebla o aerosoles (dependiendo del tamaño de las partículas que los componen) degrada o incluso impide la visibilidad de ciertas áreas. En caso de un desastre, esto puede causar problemas operativos al retrasar o impedir totalmente la adquisición de datos. Este problema surge con mayor frecuencia en desastres relacionados con el clima (inundaciones, huracanes, etc.) o en lugares donde el terreno favorece la presencia de nubes (islas, costa, zonas montañosas). Dependiendo del ángulo de iluminación solar y el ángulo de observación, algunas zonas de la escena quedan en sombra y son más difíciles de interpretar al haber un menor contraste. Cuanto mejor sea la resolución radiométrica, más se distinguirá el daño en las áreas de sombra.

Las imágenes ópticas de resolución media o alta (30 m a 5 m) dan una idea del alcance de los cambios y su distribución sin detalle a nivel de edificio, los siguientes estudios utilizaron las imágenes multiespectrales para el estudio de detección de cambios [31, 88, 124]. Su ventaja es proporcionar información en un área geográfica amplia.

La selección de las bandas de las imágenes multiespectrales se basa en la firma espectral a estudiar. Si el fenómeno a analizar se caracteriza por un cambio en la respuesta de reflectividad o emisividad a una cierta longitud de onda, el estudio de esa banda será de gran utilidad. Así, la banda del infrarrojo cercano permite una fácil discriminación de la vegetación, utilizando el índice de vegetación en diferencias



Figura 2.2: Imagen óptica tomada por el satélite SPOT 6 en Argel, Argelia con una resolución de 1,5 m. **Fuente:** Airbus Defence & Space 2012, n.d.

normalizado NDVI. La resolución espacial de las imágenes multispectrales para un mismo satélite es inferior a la de las imágenes pancromáticas, así se debe llegar a un compromiso entre la resolución espacial y espectral que nos puede proporcionar un sensor. En general, las imágenes multispectrales pueden detectar mejor el daño gracias a una mejor caracterización espectral.

- **Imágenes hiperspectrales:** se obtienen a partir de un conjunto elevado de bandas espectrales (a partir de 20) obtenidas en diferentes longitudes de onda. Estas imágenes proporcionan mucha información sobre las propiedades físicas de los objetos observados [239–241]. Actualmente no hay ningún sensor hiperspectral embarcado en satélite, pero hay varias misiones previstas, que contemplan entre 210 y 249 bandas espectrales y una resolución espacial entre 8 y 30 m. El resto de sensores hiperspectrales son aerotransportados y permiten una resolución espacial variable dependiendo de la altitud del vuelo (de 30 m a aproximadamente 1 m de resolución). Podemos citar el caso de *Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)* con 224 bandas. Este tipo de sensor no se suele emplear en la evaluación de daños causados por desastres debido a su reciente aparición y a la falta de sensores satelitales.
- **Imágenes radar:** se obtienen a partir de la retrodispersión de la superficie terrestre cuando una onda electromagnética polarizada (Horizontal H o Vertical V) en el espectro de microondas incide sobre ella de forma oblicua. Estas imágenes tienen una gran ventaja sobre las ópticas en que pueden adquirirse de día o de noche, independientemente de las condiciones climáticas [242]. Las imágenes de radar de resolución media son, por lo tanto, una valiosa ayuda para la evaluación rápida de

cambios que afectan a grandes áreas, por ejemplo, después de una inundación. La figura 2.3 representa un mosaico de 46 capturas tomadas por el satélite TerraSAR-X en el lago Constanza, Alemania. Así como en el caso de las imágenes ópticas es posible hasta cierto punto estimar el cambio en una sola imagen de crisis para ciertos desastres, es prácticamente imposible evaluar el daño mediante una sola imagen de radar.

La geometría de adquisición es muy diferente al sistema de adquisición óptico, ya que en el dominio cruzado se establece un sistema de proyección cilíndrico. Así, el aprovechamiento que se puede realizar en algunos casos, por ejemplo en fachadas de edificios, es mayor que el proporcionado por los productos ópticos.

Las imágenes SAR permiten, entre otras cosas, medir cambios en la altura de un objeto (en el caso de la erosión de un edificio o sus plantas, por ejemplo) por interferometría, el estado de la superficie de un blanco (aparición de desechos o escombros) y su contenido de agua (especialmente en el caso de inundación). Tanto la medida de la coherencia como el cálculo del interferograma requieren condiciones de adquisición ligeramente diferentes. En el caso de detección de cambios, es necesario esperar un período mínimo para que el satélite adquiera la misma escena con un ángulo de incidencia próximo al de la imagen de referencia (12 días para Sentinel-1A). Al igual que con las imágenes en el dominio visible, la resolución de la imagen influye en el tamaño de los objetos y el tipo de daño detectable. Es obvio que el análisis multitemporal de imágenes SAR con resolución espacial media puede utilizarse para la detección rápida de cambios a gran escala. Sin embargo, los datos MAR (ópticos o de radar) siguen siendo necesarios para un mapeo preciso del cambio. El rápido despliegue de nuevas misiones facilita la posibilidad de realizar detección de cambio con imágenes radar tal como se usaron en los siguientes estudios [76, 128, 190]

2.2.2 Concepto de resolución

En cuanto a la resolución de las imágenes de satélite, distinguimos cuatro tipos: resolución espacial, espectral, radiométrica y temporal [242].

- **Resolución espacial:** se refiere a la distancia más pequeña entre dos objetos adyacentes que el sensor puede identificar. Cuanto mejor sea la resolución espacial, mayor será el tamaño de las imágenes y el tiempo de procesado.
- **Resolución espectral:** se emplea en el marco de los sensores en el espectro óptico y se refiere al ancho de banda más pequeño que el sensor puede discernir. Cuanto más fina es la resolución espectral, más estrechas y numerosas son las ventanas espectrales de los diferentes canales del sensor.



Figura 2.3: Mosaico de 46 capturas tomadas con el instrumento StripMap del satélite TerraSAR-X en el lago de Constanza, Alemania. **Fuente:** Airbus Defence & Space, n.d.

- **Resolución radiométrica:** se relaciona con la capacidad de un sistema de teledetección para reconocer pequeñas diferencias en la energía electromagnética recibida. Cuanto más fina es la resolución radiométrica de un sensor, más sensible es el sensor a pequeñas diferencias en la energía recibida. El rango de posibles valores de energía adquirida en un sensor se denomina rango dinámico.
- **Resolución temporal:** se refiere al período de tiempo que tarda un satélite en adquirir datos en la misma zona bajo las mismas condiciones de adquisición. Depende de una variedad de factores que incluyen las características orbitales del satélite, el diseño del sensor, las huellas de los sensores en suelo, y la latitud del lugar a observar.

2.2.3 Misiones de satélites de teledetección

La mayoría de los países desarrollados dedican recursos gubernamentales a la teledetección a través de programas propios o a través de agencias internacionales. Se han lanzado ya un gran número de satélites y la tendencia es conseguir cada vez más productos con una mejor resolución espacial y espectral gracias a los avances tecnológicos. Varias agencias espaciales gestionan programas de teledetección a largo plazo: ESA, NASA, JAXA, *Centre National d'Études spatiales (CNES)* o DLR. En esta sección se presentan las misiones más relevantes en el marco de la detección de cambio en caso de desastre natural por teledetección.

2.2.3.1 Landsat

Es una colección de satélites de la NASA que se dedica a la observación de la Tierra con imágenes de alta resolución desde hace más de cuatro décadas. Proporcionan un recurso único para la agricultura, mapeo e investigación sobre el cambio global y también son imprescindibles en la respuesta de emergencias en caso de desastre [243].

Las imágenes multiespectrales de Landsat ofrecen datos continuos desde marzo de 1984 hasta el presente, con una resolución espacial de 30 m. Es la misión escogida en el desarrollo de esta Tesis gracias a la disponibilidad de sus productos.

2.2.3.1.1 Landsat-5

La NASA cedió el control del satélite Landsat-5 al servicio USGS en marzo de 1984, y terminó su misión en noviembre 2011. Landsat-5 adquirió datos brutos de alta calidad sobre la superficie terrestre durante 28 años y 10 meses. Dispone de un sensor TM que barre desde el espectro visible al infrarrojo medio MIR a una resolución de 30 m en el sensor multiespectral. Tiene una frecuencia de paso de 16 días.

2.2.3.1.2 Landsat-7

La NASA lanzó el satélite Landsat-7 dando servicio al USGS en abril de 1999. Este satélite dispone del sensor ETM+, que permite la adquisición de imágenes del espectro visible al infrarrojo medio MIR con una resolución de 30 m en los canales multiespectrales y 15 m en el canal pancromático. Tiene una frecuencia de paso de 16 días.

2.2.3.1.3 Landsat-8

Este satélite lanzado por la NASA al servicio de USGS en mayo de 2013. Tiene un sensor *Operational Land Imager (OLI)* que permite la adquisición de datos brutos desde el espectro visible al infrarrojo de onda corta SWIR a una resolución de 30 m en los canales multiespectrales y 15 m en el canal pancromático. También tiene otro sensor *Thermal Infrared Sensor (TIRS)* que permite adquirir imágenes en bandas térmicas con una resolución de 100 m. Tiene una frecuencia de paso de 16 días. La figura 2.4 muestra una imagen tomada por el satélite Landsat-8 en Aïn Séfra (Argelia).

La tabla 2.1 resume los parámetros más importantes de las imágenes y las bandas seleccionadas de cada satélite.

Tabla 2.1: Propiedades del satélite Landsat.

Propiedad/Satélite	Landsat-5	Landsat-7	Landsat-8
Sensor	TM	ETM+	OLI/TIRS
Sistema de referencia	<i>Landsat Worldwide Reference System-2 (WRS-2)</i>		
Altitud orbital	705 km		
Resolución radiométrica	8 bits		12 bits
Periodo orbital	99 minutos	98,9 minutos	
Frecuencia de paso	16 días		
Swath	185 km		
Inclinación orbital	98,2 °		
Resolución espacial multispectral	30 m		
Banda 1 (μm)	0,45 - 0,52 (B)	0,45 - 0,52 (B)	0,43 - 0,45 (Ultra B)
Banda 2 (μm)	0,52 - 0,60 (G)	0,52 - 0,60 (G)	0,45 - 0,51 (B)
Banda 3 (μm)	0,63 - 0,69 (R)	0,63 - 0,69 (R)	0,53 - 0,59 (G)
Banda 4 (μm)	0,76 - 0,90 (NIR)	0,77 - 0,90 (NIR)	0,64 - 0,67 (R)
Banda 5 (μm)	1,55 - 1,75 (SWIR1)	1,55 - 1,75 (SWIR1)	0,85 - 0,88 (NIR)
Banda 6 (μm)	-	-	1,57 - 1,65 (SWIR1)
Banda 7 (μm)	2,08 - 2,35 (SWIR2)	2,08 - 2,35 (SWIR2)	2,11 - 2,29 (SWIR2)



Figura 2.4: Imagen óptica del sensor OLI del satélite Landsat-8 tomada en Aïn Séfra, Argelia el 8 de enero 2018 que representa la nieve en el desierto. **Fuente:** Landsat 8.

2.2.3.2 Terra

En diciembre de 1999, la NASA lanzó el satélite Terra como misión principal del programa *Earth Observing System (EOS)* [244]. Terra lleva embarcados cinco instrumentos que observan la atmósfera de la tierra, el océano, la tierra, la nieve, el hielo, y el balance de energía. En conjunto, estas observaciones proporcionan una visión única de cómo funciona el sistema de la Tierra y cómo está cambiando. Las observaciones de Terra revelan el impacto de la humanidad en el planeta y proporcionan datos cruciales sobre peligros naturales como incendios y volcanes. Terra es una misión internacional que transporta instrumentos de Estados Unidos de América, Japón y Canadá. Estos instrumentos son: *Clouds and Earth Radiant Energy System (CERES)*, *Multi-angle Imaging Spectroradiometer (MISR)*, *Moderate Resolution Imaging Spectroradiometer (MODIS)*, de Estados Unidos. *ASTER* de Japón y *Measurements of Pollution in the Troposphere (MOPITT)* de Canadá.

Los sensores embarcados en el satélite Terra ofrecen una alta resolución espacial de hasta 15 m. Estos datos no han sido usado en esta Tesis porque su archivo histórico no es tan extenso como el de Landsat.

2.2.3.3 Sentinel-2

La misión Sentinel-2 es el resultado de la colaboración entre la ESA, la Comisión Europea, la industria, los proveedores de servicios y los usuarios de datos en el marco del programa Copernicus. El programa ha sido diseñado y construido por un consorcio de alrededor de 60 compañías lideradas por *Airbus Defence and Space* y respaldada por la agencia espacial francesa CNES y por el centro aeroespacial Alemán DLR.

La misión consiste en dos satélites diseñados para caracterizar la vegetación, la

cobertura del suelo y el medio ambiente. El satélite Sentinel-2A fue lanzado por la ESA el 23 de junio de 2015 y opera en una órbita heliosíncrona con un ciclo de repetición de 10 días [245]. Las prioridades actuales de adquisición de Sentinel-2A se centran principalmente en Europa. Se lanzó un segundo satélite idéntico (Sentinel-2B) el 7 de marzo de 2017. Funcionando de forma conjunta, los dos satélites ofrecen una cobertura global excluyendo los océanos cada cinco días. Sentinel-2 *Multi Spectral Instrument (MSI)* adquiere imágenes en 13 bandas espectrales que incluyen el espectro visible, el infrarrojo cercano *Visible Near InfraRed (VNIR)* y el infrarrojo de onda corta *Short Wavelength Infrared (SWIR)* con una cobertura de 290 km de ancho.

El Sentinel-2 es un satélite reciente que complementa la misión Landsat y ofrece datos gratuitos a partir de junio de 2015. Esta es la razón por la que no se han empleado sus datos en esta tesis.

2.2.3.4 SPOT

SPOT es un programa de teledetección creado en 1978 por Francia (CNES) con la asociación de Bélgica (*Services Fédéraux des Affaires Scientifiques, Techniques et Culturelles (SSTC)*) y Suecia (*Swedish National Space Board (SNSB)*). El programa SPOT trabaja en el espectro óptico con una alta resolución espacial para la época en la que se diseñó. Este programa pretende mejorar el conocimiento y la gestión de la Tierra explorando los recursos, detectando y pronosticando fenómenos relacionados con la climatología y la oceanografía, y controlando las actividades humanas y los fenómenos naturales.

Hasta ahora, se han lanzado 7 misiones del SPOT [246]. El SPOT 1, 2, 3 representan la primera generación del SPOT con alta resolución en el espectro visible y permiten adquirir imagen pancromática y multiespectral de tres canales. El SPOT 4 constituye la segunda generación del programa que incluye el espectro infrarrojo. El SPOT 5 es la tercera generación, que permite adquirir imágenes de alta resolución espacial y en modo estereoscópico. El SPOT 6 y el SPOT 7 constituyen la última generación del programa SPOT, y conforman una constelación de satélites diseñada para garantizar la continuidad en los datos de muy alta resolución y cobertura terrestre hasta 2024. Incorporan innovaciones tecnológicas y operativas que comparte con la constelación Pléiades y proporciona imágenes MAR.

A pesar de la alta resolución y la gran precisión espacial que podría lograr en la detección de cambio el programa SPOT, sus datos no se pueden obtener fácilmente de forma gratuita, y por ello no se emplean en el marco de esta Tesis.

Tabla 2.2: Los satélites SPOT y sus características.

Satélite	SPOT 1, 2 y 3	SPOT 4	SPOT 5	SPOT 6, 7
Fecha de lanzamiento	1: 22-02-1986 2: 22-01-1990 3: 26-09-1993	24-03-1998	4-05-2002	6: 9-09-2012 7: 30-06-2014
Lanzador	Ariane 2/3	Ariane 4		Lanzador indio PSLV
Vida útil nominal	3 años	5 años		10 años
Fecha de deórbitacion	1: 17-11-2003 2: 30-07-2009 3: 14-11-1996	11-01-2013	25-03-2015	Todavía en órbita
Altitud en el ecuador	832 km			694 km
Sensor	<i>High-Resolution Visible (HRV)</i>	<i>High-Resolution Visible and InfraRed (HRVIR)</i>	<i>High-Resolution Geometric (HRG)</i> <i>High-Resolution Stereoscopic (HRS)</i>	<i>New Astrosat Optical Modular Instrument (NAOMI)</i>
Bandas espectrales y resolución	-1 pancromático a 10 m -3 multiespectrales a 20 m	-1 monoespectral a 10 m -3 multiespectrales a 20 m -1 infrarrojo medio a 20 m	-2 pancromáticas a 5 m, que permiten generar un producto a 2,5 m -3 multiespectrales a 10 m -1 infrarrojo medio a 20 m	-1 pansharpened 1,5 m -1 bundle: adquisición simultánea pancromática y multiespectral -1 pancromática a 1,5 m -3 multiespectrales a 6 m -1 infrarrojo cercano a 6 m
Campo de captura de imagen	60 km × 60 km a 80 km			120 km × 120 km o 60 km × 180 km
Dinámica de la imagen	8 bits			12 bits
Repetitividad del ciclo	2 a 3 días			1 día

2.2.3.5 Sentinel-1

Las imágenes de radar son capaces de proporcionar información en condiciones climáticas adversas y no dependen de la iluminación solar. La geología, agricultura y la clasificación de la cobertura del terreno son algunos ejemplos de aplicaciones que se benefician de esta tecnología. Sentinel-1 es una constelación de dos satélites en órbita polar para la monitorización de tierra y océanos, que adquieren imágenes de Radar de Apertura Sintética (SAR) en banda de frecuencia C (4GHz - 8 GHz) [247]. Así, el objetivo de la misión es proporcionar continuidad de datos SAR en banda C tras las misiones *European Remote Sensing Satellite Mission 2 (ERS-2)* y *Environmental Satellite (ENVISAT)*. Para lograr esto, los satélites llevan un sensor C-SAR, que ofrece imágenes de resolución media y alta. La ESA lanzó el satélite Sentinel-1A en abril de 2014. Dispone de un sensor C-SAR y permite el funcionamiento en polarización simple (HH o VV) o doble polarización (HH + HV o VV + VH), conmutando la polarización (H o V) en la cadena de transmisión e implementando dos canales paralelos de recepción (H y V). Tiene una frecuencia de paso de 12 días y sus datos están disponibles de manera abierta a través del Hub de la ESA. La tabla 2.3 resume las principales propiedades del satélite Sentinel-1A y sus cuatro modos de adquisición:

- *StripMap (SM)*: El modo *StripMap* adquiere datos con una franja de 80 km de ancho a una resolución espacial de 5 m por 5 m.
- *Interferometric Wide swath (IW)*: El modo de franja ancha interferométrica es el modo de adquisición principal sobre tierra y satisface la mayoría de los requisitos de servicio. Adquiere datos con una franja de 250 km a una resolución espacial de 5 m por 20 m.
- *Extra-Wide swath (EW)*: igual al modo IW, el modo de franja extra ancha emplea la técnica *Terrain Observation with Progressive Scans SAR (TOPSAR)* para adquirir datos en un área mucho más amplia utilizando cinco franjas secundarias. El modo EW adquiere datos en una franja de 400 km a 20 m por 40 m de resolución espacial.
- *Wave (WV)*: es similar a las imágenes *Wavemode* ERS-2 y ENVISAT pero con una resolución mejorada y un nuevo patrón de adquisición. El modo *Wavemode* adquiere datos en ventanas de 20 km por 20 km, con una resolución espacial de 5 m por 5 m, cada 100 km a lo largo de la órbita, adquiridas alternativamente en dos ángulos de incidencia diferentes.

Sentinel-1A es la primera de las cinco misiones que ESA desarrolla para la iniciativa Copernicus. Los objetivos de la misión son :

- Monitorización de las zonas de hielo y el medio ambiente del Ártico.
- Vigilancia del medio marino y los vertidos de combustible y detección de buques (seguridad marítima).
- Seguimiento de los riesgos de desplazamiento de superficies terrestres.
- Cartografía de superficies terrestres: bosque, agua y suelo, agricultura sostenible, desertificación.
- Cartografía para la ayuda humanitaria en situaciones de crisis.
- Monitorización del clima.

Las imágenes del Sentinel-1A han sido incorporadas en el proceso de detección de desertificación desarrollado en la sección 5.5 de esta tesis porque proporcionan información valiosa en la banda C de frecuencia, y por la disponibilidad de datos en la zona de estudio de forma abierta, gracias a la política de diseminación de datos del programa Copernicus.

Tabla 2.3: Propiedades del satélite Sentinel-1A.

Propiedad/ Modo de adquisición	SM	IW	EW	WV
Sensor	C-SAR			
Sistema de referencia	Geocentric y geodetic			
Altitud orbital	693 km			
Resolución radiométrica	10 bits			
Periodo orbital	98,6 minutos			
Frecuencia de paso	12 días			
Inclinación orbital	98,18°			
Swath	80 km	250 km	400 km	20×20 km
Resolución espacial	5×5 m	5×20 m	20×40 m	5×5 m
Polarización	HH o VV HH+HV VV+VH			HH o VV

2.2.3.6 TerraSAR-X y TanDEM-X

TerraSAR-X es un satélite alemán de imágenes de radar gestionado por DLR, lanzado el 15 de junio 2007 [248]. Incluye un SAR en banda X con diferentes modos de operación. Es el primer satélite radar comercial que proporciona datos de alta resolución (1 m) consiguiendo una gran precisión geométrica y radiométrica. Se considera como un complemento perfecto a los datos ópticos MAR y la mejor solución para capturar en zonas con nubosidad persistente.

Se lanzó un satélite gemelo TanDEM-X el 21 de junio 2010 con el objeto de mejorar el tiempo de adquisición y para disponer de un *Digital Elevation Model (DEM)* global de gran calidad mediante interferometría SAR [248]. TerraSAR-X opera con diferentes modos de adquisición:

- *Staring SpotLight (ST)*: con una resolución de hasta 0,25 m. Tamaño de la escena de 4 km (ancho) \times 3,7 km (largo) a 60°, empleando polarización simple.
- *High-Resolution Spotlight (HS)*: con una resolución de hasta 1 m. Tamaño de la escena de 5 a 10 km (ancho) \times 5 km (largo), empleando polarización simple o doble.
- *Spotlight (SL)*: con una resolución hasta 1,7 m. Tamaño de la escena de 10 km (ancho) \times 10 km (largo), empleando polarización simple o doble.
- *StripMap (SM)*: con una resolución hasta 3 m. Tamaño de la escena de 30 km (ancho) \times 50 km (largo), empleando polarización simple, doble o cuádruple.
- *ScanSAR (SC)*: con una resolución hasta 18,5 m. Tamaño de la escena de 100 km (ancho) \times 150 km (largo). Polarización simple.
- *Wide ScanSAR (WS)*: con una resolución hasta 40 m. Tamaño de la escena de 270 km (ancho) \times 200 km (largo), y longitud de escena de hasta 1500 km, empleando polarización simple.

La banda X ofrece información adicional a las imágenes ópticas debido a sus especiales características de retrodispersión en objetos hechos por el hombre, y permite una observación sistemática bajo casi cualquier condición climática. No obstante, no se ha podido disponer de imágenes de esta banda de frecuencia en la zona de estudio en esta Tesis.

Teniendo en cuenta la descripción anterior sobre el potencial de los diferentes tipos de imágenes y su disponibilidad, el análisis que se llevará a cabo en el marco de esta Tesis se centrará en las imágenes multiespectrales de Landsat y las imágenes SAR de Sentinel-1A.

Técnicas básicas de análisis

Este capítulo resume las técnicas y herramientas básicas necesarias para el desarrollo posterior de la Tesis. Incluye correcciones de imagen, clasificación, detección de cambio y evaluación de calidad.

Aquí se detallan los tipos de correcciones de imágenes ópticas y de radar. Se explican distintos tipos de clasificación, y diferentes métodos de detección de cambio. También, se presentan las herramientas de evaluación de resultados mediante las matrices de confusión, matrices de transición e índices de cambio.

3.1 Corrección de imágenes de satélite

La imagen que transmite el satélite requiere un trabajo de procesado previo a su explotación. Por ello, es necesario realizar una serie de operaciones de corrección que pueden incluir, dependiendo de la aplicación final: correcciones radiométricas, atmosféricas, geométricas, y operaciones de co-registro. El programa ENVI [249] que permite analizar y extraer información a partir de las imágenes de teledetección y SIG ha sido seleccionado para corregir y clasificar los datos.

3.1.1 Corrección radiométrica

Normalmente las estaciones de procesado en tierra realizan una primera corrección radiométrica de sus productos, que normalmente se complementa con las correcciones que realizará el usuario antes de tratar los datos. Esta última consiste en eliminar las distorsiones debidas a anomalías que afectan a los sensores tales como el envejecimiento y los errores residuales que afectan a la imagen durante la aplicación de otras correcciones. En este tipo de corrección se cambia el valor radiométrico de los píxeles para obtener los mejores resultados de clasificación o detección de cambio en este trabajo.

El proceso de corrección radiométrica permite convertir la información original de los píxeles (ND) a niveles de reflectancia [242]. En ella se reducen los efectos de la dispersión o absorción causadas por la existencia de partículas en la atmósfera. Por otra parte, permite reducir el efecto producido por el ángulo de observación y de iluminación solar. Este tipo de corrección es imprescindible en el caso de emplear imágenes con distintos sensores.

La corrección radiométrica también incluye la restauración de líneas o píxeles perdidos. Cuando se pierde el valor de un píxel, su recuperación se hace con la estimación de la media de los valores del mismo píxel en las líneas anteriores y posteriores. Dependiendo del tipo de sensor empleado, esta estimación puede no ser fiable cuando se usan píxeles vecinos de la misma línea. También se pueden emplear valores de otras bandas para ayudar en la estima. En general, la pérdida de una línea completa se soluciona del mismo modo.

Además se corrige el efecto inter-banda producido por operar con distintas bandas espectrales con distintos sensores. Se puede producir una distorsión por una calibración deficiente de los detectores de las distintas bandas, que se hace más evidente en áreas de bajo ND. Para su corrección se calculan los histogramas de cada detector y se comparan. Se obtienen los coeficientes r_l y s_l , que sirven para corregir la salida de cada detector de forma lineal:

$$r_l = z - s_l z_l, \quad (3.1)$$

$$s_l = y/y_l, \quad (3.2)$$

donde z_l y y_l son la media y la desviación estándar de los ND correspondientes a cada detector l y z e y representan la media y desviación estándar del conjunto de píxeles de la imagen. El ND corregido se describe en la siguiente expresión:

$$ND'_{i,j} = r_l + s_l ND_{i,j}, \quad (3.3)$$

donde $ND'_{i,j}$ es el nivel digital corregido y $ND_{i,j}$ es el nivel digital que presenta el efecto de falta de calibración inter-banda.

En general con estas correcciones se busca minimizar los errores y hacer que las imágenes de distintas fechas estén preparadas para la comparación.

3.1.1.1 Corrección atmosférica

Consiste en eliminar las distorsiones de la atmósfera en la imagen. Principalmente consiste en detectar zonas con neblina y nubes mediante un examen detenido de la imagen. El fruto final del proceso de corrección atmosférica es una imagen de valores de radiancia que mejora la separabilidad espectral de los objetos presentes en la imagen corregida con respecto a la imagen original. La radiancia recibida por el sensor no representa el mismo valor procedente de la radiancia del suelo porque ha atravesado la atmósfera, que contribuye con distintos efectos a la radiancia a nivel de suelo. El proceso de corrección atmosférica es esencial en el caso de estudios temporales porque la distorsión varía entre unos días a otros [242]. Se pueden usar diferentes métodos para su corrección, el mínimo del histograma, la regresión y otros algoritmos complejos como LOWTRAN o los modelos 5S, 6S, que necesitan información detallada de la atmósfera en el momento de la adquisición de la imagen [250].

3.1.2 Corrección geométrica

La corrección geométrica de imágenes de satélite consiste en superponer varias capas de información incluyendo la orografía, datos vectoriales auxiliares teniendo en cuenta el tiempo de adquisición y la posición del satélite entre otros. Este proceso permite corregir los desplazamientos y distorsiones geométricas presentes en una imagen, causados por la inclinación del sensor, la influencia del relieve y algunos errores sistemáticos asociados con la imagen [242]. Esta parte del proceso es determinante porque tiene implicaciones directas en la precisión de los resultados. En el caso de estimación de cambios, la corrección geométrica garantiza que los cambios reportados entre dos imágenes de la misma zona y distintas fechas, se deban a cambios reales y no a diferencias en la posición de los objetos. Para ese propósito es recomendable emplear orto-rectificación usando el MDT.

La georreferenciación también es una etapa muy importante en la detección de cambios porque permite la superposición precisa de los píxeles en diferentes escenas del satélite [242]. Después de la georreferenciación cada píxel se localiza con los valores de longitud y latitud que le pertenecen en un sistema de coordenadas estándar (*World Geodetic System 1984 (WGS84)*, *Universal Transverse Mercator (UTM)*). Las correcciones requeridas para localizar cada píxel (a, b) en sus coordenadas reales UTM (x, y) se describen con las siguientes ecuaciones:

$$x = a_1(a, b), \quad (3.4)$$

$$y = a_2(a, b). \quad (3.5)$$

Básicamente existen dos métodos para efectuar la georreferenciación:

1. El primero es la corrección con datos orbitales, que caracteriza completamente las fuentes de error y las corrige. Es muy importante conocer las características de la órbita y la estabilización del sensor en el satélite. Éste método necesita mucha información e implementar las ecuaciones de georreferenciación.
2. El segundo es el método empírico, que permite modelar los errores en la imagen usando puntos de control. Es muy sencillo y corrige mejor los errores aleatorios, pero necesita una intervención del analista. De forma general se ajustan los coeficientes de modelos polinómicos que pueden transformar de forma adecuada las coordenadas de la imagen. En función del tipo de deformación de la imagen se determina el tipo de transformación adecuado y el orden del modelo polinómico. Cuanto mayor sea el grado de los polinomios, más sensible será la transformación a los errores en la selección de los puntos de control. Habitualmente se usa la transformación lineal del primer orden.

$$x = Lb + Ma + N \quad (3.6)$$

$$y = Ob + Pa + Q \quad (3.7)$$

Los valores de los coeficientes de regresión L, M, N, O, P, Q se calculan mediante el método de ajuste por mínimos cuadrados. En este proceso, se obtiene también el *Root Mean Square Error (RMSE)*:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x' - x)^2 + (y' - y)^2}{n}}, \quad (3.8)$$

donde x' y y' representan las coordenadas estimadas por la transformación para cada punto de control seleccionado (de los n puntos de control). Este valor es una estima de la calidad del proceso. Finalmente, se aplican las ecuaciones 3.6 y 3.7 con los coeficientes calculados a todos los píxeles de la imagen.

3.1.2.1 Registro

La etapa de registro consiste en establecer una concordancia de posición espacial entre los dos volúmenes correspondientes al mismo objeto físico. Es un paso indispensable para la comparación de imágenes anatómicas, la fusión de imágenes y otros procesos.

La etapa de registro de imagen alinea geoméricamente píxel a píxel dos imágenes con diferente geometría de visualización y diferentes distorsiones de fondo en el mismo sistema de coordenadas, de modo que los píxeles correspondientes representen los mis-

mos objetos [242, 251]. El proceso incluye localizar y hacer coincidir una serie de puntos característicos llamados puntos de enlace TIE en dos imágenes (una imagen de deformación y una de base). Los puntos correspondientes se utilizan para calcular los parámetros de la transformación geométrica entre los dos imágenes. Este registro es necesario para las imágenes tomadas con diferentes tipos de sensores, diferentes tipos de bandas de frecuencia (óptico, radar), diferentes ángulos de visión (elevación y acimut) y por último imágenes con diferentes características (resolución espacial, relación señal a ruido, bandas espectrales).

3.1.3 Filtro Speckle

El ruido de fase (Speckle) esta causado por la interferencia constructiva y destructiva de ondas de retorno desfasadas pero coherentes causadas por retrodispersores elementales dentro de cada celda de resolución [252]. Uno de los métodos para reducir el ruido Speckle consiste en aplicar un filtro paso bajo más o menos sofisticado.

El ruido Speckle se manifiesta en imágenes con iluminación coherente. Este es el escenario de un sistema SAR, en el que la señal (valor complejo) tiene un ancho de banda elevado, pero en términos relativos frente a la frecuencia de trabajo se puede considerar de banda estrecha [253]. Es un ruido multiplicativo y no Gaussiano (en el valor absoluto de la muestra), y dificulta la interpretación de las imágenes.

El ruido Speckle se crea por la suma de las contribuciones de carácter aleatorio de elementos retrodispersores individuales separados por distancias comparables a la longitud de onda de trabajo. Debido a que el Speckle constituye una forma de ruido (no aporta información útil), generalmente se intenta reducir bien mediante procesos *Multilook*, que degradan la resolución espacial, o bien mediante filtrado paso bajo. En este último caso se corre el riesgo de eliminar la información original de la escena, así que hay que llegar a un compromiso entre presencia de ruido y preservación del detalle en la textura de la imagen [254].

En el caso del filtrado paso bajo, se utilizan filtros adaptados a los estadísticos de la zona. La mayoría de los filtros para reducción de Speckle comúnmente utilizados tienen buenos resultados para suavizar el ruido. Aunque, las imágenes resultantes siempre están sujetas a una degradación de la resolución tanto espacial como radiométrica. Este deterioro incluye una pérdida de información de la imagen en mayor o menor medida, dependiendo del comportamiento del filtro utilizado. La cantidad deseada de reducción de ruido Speckle debe estar balanceada con la cantidad de detalle requerido para la escala espacial y para la naturaleza de la aplicación en cuestión. Para interpretaciones a gran escala, los detalles minuciosos pueden ser en muchos casos ignorados. Así, un filtrado amplio del ruido Speckle y consecuentemente, con pérdida de detalles de la imagen puede ser aceptable o apropiado.

Mientras que para aplicaciones donde los detalles finos y de alta resolución son necesarios, el filtro Speckle debe enfocarse en la preservación de detalles [253]. Este aspecto puede ser tan importante como a su vez la reducción del ruido Speckle. Los filtros más utilizados son el filtro Lee y el filtro Frost, que ajustan la capacidad de filtrado en función de los parámetros estadísticos de los píxeles vecinos definidos por una ventana.

3.2 Clasificación

La etapa de clasificación es la más importante en la detección de cambio, ya que en esta Tesis se van a trabajar algoritmos basados en ella. En concreto se desarrollan los algoritmos de clasificación supervisada que requieren una etapa de entrenamiento empleando un conjunto de clases predeterminadas. Para ello se estudian las características de los valores de reflectancia de las diferentes bandas en las regiones de interés.

3.2.1 Clasificación por píxel

La clasificación por píxel consiste en estudiar estadísticamente sus valores espectrales con independencia de su posición y asignarlo a una categoría en base a su similitud con otros píxeles de la escena [242]. Esta metodología ofrece buenos resultados para imágenes de media y baja resolución espacial. Sin embargo, sus resultados dependen de muchos factores, principalmente del tipo de escena a clasificar.

En esta Tesis se usan diferentes tipos de clasificadores y se selecciona el clasificador que permite clasificar la cobertura terrestre con resultados satisfactorios. La principal fuente de error es la existencia de píxeles mixtos que representan mezclas entre diferentes clases, por lo que requerirían un análisis sub-píxel empleando imágenes de más resolución espacial [95].

La figura 3.1 presenta una muestra de las zonas de entrenamiento empleadas para clasificar una imagen del año 2000 en la región de Pekín (China).

3.2.1.1 Tipos de clasificadores por píxeles

Se usan diferentes tipos de clasificadores para un estudio comparativo de los resultados. Los métodos empleados para clasificar las imágenes con clasificadores supervisados por píxel son:

- Distancia mínima: que permite usar dos vectores medios de cada clase y calcular la distancia euclidiana entre cada píxel desconocido y el vector medio por cada clase. Cada píxel se clasifica con la etiqueta de la clase más cercana.
- Distancia Mahalanobis: este clasificador usa estadísticos para cada clase, haciendo

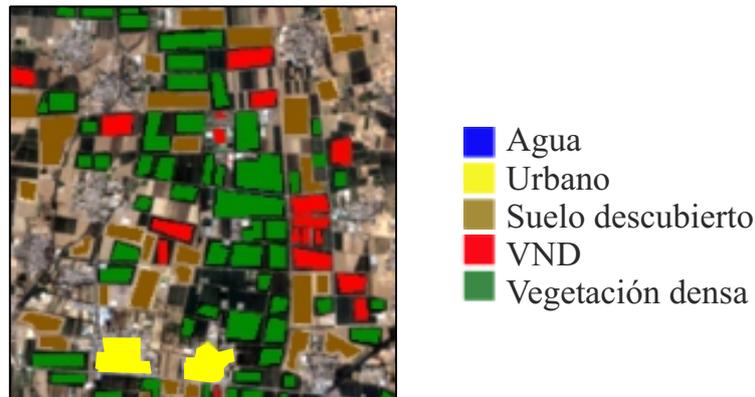


Figura 3.1: Muestra de zonas de entrenamiento para clasificar la imagen.

la distancia sensible a cada dirección. Es similar al *Maximum Likelihood Classifier (MLC)*, pero incluye las covarianzas entre clases en su formulación. Todos los píxeles se clasifican según los datos de entrenamiento más cercanos en la nueva métrica.

- *Spectral Angle Mapper (SAM)*: es una clasificación espectral basada en ángulos para asignar un píxel a una clase determinada. El método SAM compara el ángulo entre el vector medio de entrenamiento y cada vector de píxel en el espacio. Los ángulos más pequeños representan coincidencias más cercanas al espectro de referencia. Los píxeles se clasifican en la clase con el ángulo más pequeño.
- MLC: usa los estadísticos para cada clase en cada banda, con distribución normal y se calcula la probabilidad de que un píxel determinado pertenezca a una clase específica. La clasificación se hará con la asignación a la clase que tiene la mayor probabilidad.
- *Support Vector Machine (SVM)*: es un clasificador supervisado derivado de la teoría del aprendizaje estadístico. Permite separar las clases con una superficie de decisión que maximiza el margen entre ellas. Se usa como clasificador por píxel y por objetos. Puede emplear cuatro tipos de núcleo: uno lineal, y tres tipos no lineales (polinomial, de función de base radial, y sigmoideo).

3.2.2 Clasificación por objetos

En esta clasificación se considera la distribución espacial que existe en una imagen para agrupar píxeles vecinos con características semejantes. Este tipo de clasificación ha tenido mucho interés por parte de los investigadores y se entiende como una nueva sub-disciplina empleada en los últimos años [160, 210, 255–257]. Gracias al procesado en el dominio espacial, se pueden desarrollar técnicas y herramientas para que la interpretación del analista de la imagen se simplifique. También aumenta la precisión de los resultados y los hace menos dependientes de la subjetividad del analista. El análisis de imágenes por objetos tiene en cuenta información espacial, espectral y temporal.

Este proceso de clasificación se basa en primer lugar en la segmentación de la imagen teniendo en cuenta las características de los objetos en dos pasos, la creación de objetos más fina y la agrupación de objetos. El objetivo de la segmentación es establecer una colección de objetos representativa, significativa y fácil de interpretar. La figura 3.2 muestra las etapas para del proceso de clasificación por objetos.

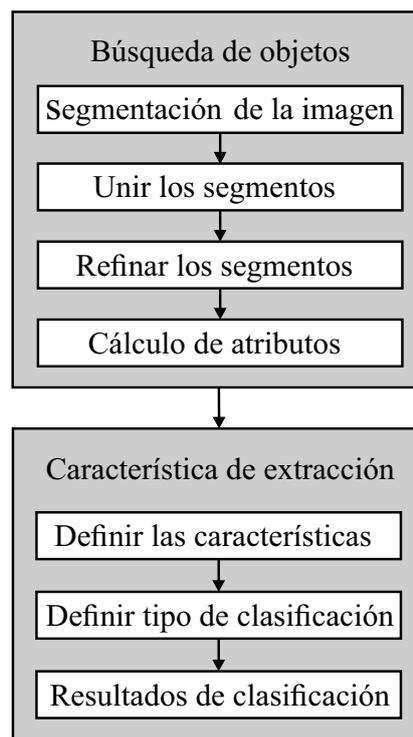


Figura 3.2: Diagrama de flujo de la segmentación y clasificación por objetos.

El resultado final de la clasificación es un conjunto de objetos que cubren toda la imagen. Cada objeto contiene píxeles similares en una o más características. Las imágenes pueden segmentarse en objetos de mayor o menor tamaño según el problema a resolver.

Los parámetros más decisivos en la clasificación son la resolución de la imagen, el tamaño de los objetos a definir y la escala. Para obtener resultados precisos, este estudio emplea los atributos espectrales, espaciales y de textura. Se usa la opción de bordes de la segmentación para mejor detección de límites y la opción *Full Lambda Schedule* para la unión de segmentos que permite la fusión de segmentos adyacentes basados en una combinación de información espectral y espacial.

Los atributos utilizados para describir las características de los objetos se clasifican como:

- **Atributos espectrales:** estos atributos proporcionan información sobre la respuesta espectral de cada banda de las imágenes de entrada [258]. Esta información estadística se resume con la media aritmética, la desviación estándar y los valores máximos o mínimos. Todos los píxeles del mismo grupo contribuyen al cálculo del atributo y se puede completar la descripción de un objeto con la comparación con los objetos vecinos.
- **Atributos de textura:** los atributos de textura se calculan sobre cada banda de la imagen de entrada. Existen numerosos métodos para proporcionar las características de textura en una imagen [259]. El método más usado habitualmente trabaja con la matriz de co-ocurrencia de nivel de gris, que describe los parámetros: rango de datos, promedio, varianza y entropía. El rango se obtiene con el máximo y el mínimo de la matriz de co-ocurrencia. El promedio permite tener una idea del brillo global del objeto. La varianza es una medida de la dispersión de los valores alrededor del promedio y la entropía se calcula en función de la distribución de los valores de la matriz de co-ocurrencia y permite medir el desorden en el objeto.
- **Atributos espaciales:** los atributos espaciales se calculan a partir del polígono de cada objeto que define el límite de los píxeles, por lo que no se requiere información de distintas bandas [260]. Estas características permiten describir la morfología y la dimensión de los píxeles, que se pueden resumir en: área, longitud, grado de compacidad, convexidad, solidez, redondez, elongación, factor de forma, ajuste rectangular y dirección principal. Todas estas características facilitan la distinción de los objetos con una forma determinada, como edificios o carreteras.

La figura 3.3 representa un ejemplo de los atributos reales usados en una clasificación por objetos. En la primera columna se indica el nombre de los objetos seleccionados de cada clase y en la primera línea se indican los nombres de atributos, el resto de las celdas representan sus valores. Para cada banda usada en el proceso de segmentación, se obtienen los atributos espectrales y de textura, donde x es el número de la banda.

Entre los atributos espectrales, se puede usar la media espectral, el máximo espectral, el mínimo espectral y la desviación estándar espectral. En los atributos de textura se obtiene el rango de textura, media de textura, varianza de textura y la entropía de textura. Los atributos espaciales se obtienen a partir del polígono del objeto que define el límite de los píxeles. Se calcula el área, la longitud, la compacidad, la convexidad, la solidez, la redondez, el factor de forma, la elongación, la forma rectangular, la dirección principal, la mayor longitud, la menor longitud, el número de agujeros y el área del agujero. La tabla 3.1 describe los nombres de atributos y sus descripciones.

Class_name	AVG_B_0	AVG_B_1	MIN_B_6	MAX_B_0	MAX_B_6	TXRAN_B_2	TXAVG_B_6	TXVAR_B_4
Class 1	36,999320	81,256690	-45,201580	88,727710	-39,957480	20,55928	-43,74608	1,57022
Class 1	30,716330	77,575970	-45,791530	38,183150	-42,645080	28,79176	-44,04437	4,69407
Class 2	17,724630	60,599400	-47,495860	28,227400	-43,759450	52,79538	-45,8806	14,28238
Class 2	23,419460	63,732960	-47,692520	51,202210	-43,562800	25,82144	-45,49492	2,95855
Class 3	24,738630	72,824550	-47,299210	35,119840	-42,907280	41,70107	-44,56346	7,50696
Class 3	26,826410	70,096260	-47,692520	61,923780	-42,448430	25,77781	-44,79058	3,10622
Class 4	15,508020	56,750480	-47,626970	28,993230	-43,890550	44,39169	-45,73406	8,35039
Class 4	24,793530	71,613700	-46,184840	36,651500	-42,579530	44,38583	-44,46125	9,92016
Class 5	33,843460	82,667610	-43,956100	38,948970	-42,513980	30,79730	-43,65991	3,34741
Class 5	38,523510	90,968120	-43,497250	43,543940	-41,792920	26,44741	-42,75716	3,14634
Class 5	34,507180	84,940540	-44,873820	42,778110	-41,858470	30,15600	-43,27874	6,33637

Figura 3.3: Muestra de valores de atributos usados en la clasificación por objetos.

3.2.2.1 Tipos de clasificadores por objetos

Se usan diferentes tipos de clasificadores para un estudio comparativo de los resultados. Los métodos empleados para clasificar las imágenes con clasificadores supervisados por objetos son:

- SVM: es un método de clasificación supervisado que proviene de la teoría estadística del aprendizaje. Hace una separación entre clases con la decisión que maximiza el margen entre ellas porque eso minimiza el riesgo de errores de clasificación. El tipo de kernel *Radial Basis Function (RBF)* gaussiana se selecciona para la etapa de clasificación [261, 262]. Este kernel mapea linealmente las muestras en un espacio dimensional más alto, y pueda manejar el caso cuando la relación entre las etiquetas de clase y los atributos no es lineal. El kernel RBF requiere elegir dos parámetros:
 - a. El parámetro γ , que representa la función radial gaussiana óptima y controla el ancho del núcleo. Este parámetro γ es el inverso de la desviación estándar del

Tabla 3.1: Los tipos de atributos y sus descripciones.

Tipo del atributo	Nombre del atributo	Descripción
Atributos espectrales	(AVG_{Bx})	Media espectral
	(MAX_{Bx})	Máximo espectral
	(MIN_{Bx})	Mínimo espectral
	(STD_{Bx})	Desviación estándar espectral
Atributos de textura	$(TXRAN_{Bx})$	Rango de textura
	$(TXAVG_{Bx})$	Media de textura
	$(TXVAR_{Bx})$	Varianza de textura
	$(TXENT_{Bx})$	Entropía de textura
Atributos espaciales	(FX_{AREA})	Área
	(FX_{LENGTH})	Longitud
	$(FX_{COMPACT})$	Compacidad
	(FX_{CONVEX})	Convexidad
	(FX_{SOLID})	Solidez
	(FX_{ROUND})	Redondez
	$(FX_{FORMFAC})$	Factor de forma
	(FX_{ELONG})	Elongación
	$(FX_{RECT,FI})$	Forma rectangular
	$(FX_{MAIN,DI})$	Dirección principal
	$(FX_{MAJAXLN})$	Mayor longitud
	$(FX_{MINAXLN})$	Menor longitud
	$(FX_{NUMHOLE})$	Número de agujeros
$(FX_{HOLESOL})$	Área del agujero	

núcleo RBF, se usa como medida de similitud entre dos puntos. Un pequeño valor de γ define una función gaussiana con una gran varianza, donde dos puntos se pueden considerar similares aunque estén lejos el uno del otro. Por otro lado, un valor de γ grande significa definir una función gaussiana con una pequeña varianza y en este caso, los dos puntos se consideran similares solo si están cerca el uno del otro. El valor de γ debe ser siempre superior a 0,01.

- b. El parámetro de penalización C , que controla la penalización de los errores de clasificación. Este parámetro C permite un cierto grado de clasificación errónea que es particularmente importante para los conjuntos de entrenamiento no separables. Controla la compensación entre permitir errores de entrenamiento y forzar márgenes inflexibles. Crea un margen suave que permite algunas clasificaciones erróneas, como permitir algunos puntos de entrenamiento en el lado incorrecto del hiperplano. Un valor alto del parámetro de penalización aumenta el coste de clasificar erróneamente los puntos y fuerza la creación de

un modelo más preciso que puede que no generalice bien.

Este método de clasificación se basa en algunas muestras de entrenamiento para cada tipo de uso de suelo seleccionado por el operador humano.

- *K-Nearest Neighbors (KNN)*: el método KNN calcula la distancia euclidiana de cada segmento en la imagen de segmentación a cada región de entrenamiento que se define por el analista [263]. La distancia se mide en el espacio n -dimensional, donde n es el número de atributos para esa región de entrenamiento. Este método trata todos los atributos calculados por ENVI de manera igual. Usa el campo vecinos para establecer el número de regiones de entrenamiento vecinas a considerar. Su valor es un entero impar, que va de 1 a un valor menor o igual al número total de regiones de entrenamiento para todas las clases. Un valor más alto del campo vecinos tiene en cuenta más vecinos al elegir una clase y puede reducir las características del ruido. El valor 1 significa que el objeto se asigna a la clase de su vecino más cercano en el espacio n -dimensional. También usa un umbral para indicar el nivel de confianza de que los objetos más cercanos representan la misma clase. Los valores más altos significan más confianza, por lo que solo se clasificarán los objetos más cercanos. A medida que aumente el valor del umbral mostrará más objetos sin clasificar. A medida que disminuya el valor del umbral mostrará menos segmentos no clasificados. El valor 0 significa que todos los segmentos serán clasificados.
- *Principal Component Analysis (PCA)*: la clasificación basada en PCA compara cada objeto en la imagen segmentada con los objetos de entrenamiento en el espacio del componente principal [264]. Los atributos están normalizados para tener una media cero y una varianza igual a la unidad. Los autovectores y los valores propios se calculan en función de los atributos de los objetos de entrenamiento. Los vectores propios principales (aquellos que corresponden a valores propios distintos de cero) se utilizan para transformar los atributos en el espacio del componente principal para su comparación. Se calcula lo que supera cada segmento al umbral de cada clase. El segmento se asigna a la clase con la puntuación más alta. El método PCA calcula las puntuaciones de las clases en función de las muestras de entrenamiento que selecciona el operador. Si todas las puntuaciones de clase son negativas para una región determinada, se clasificará sin etiqueta.

3.3 Detección de cambios

Existen distintos tipos de técnicas de detección de cambios, presentadas en la revisión del Estado del Arte (sección 1.2). De entre ellas se introducen aquellos métodos que se van a desarrollar con posterioridad en la Tesis. Las técnicas CVA y PCC son las técnicas estudiadas en profundidad y la técnica de Interpretación Visual se requerirá en numerosas ocasiones en las etapas de entrenamiento y validación.

3.3.1 Análisis Vectorial de Cambio (CVA)

La técnica de análisis de cambio con vectores CVA se ha utilizado con frecuencia en la última década para la detección de cambios, tal y como se describe en la sección que revisa el Estado del Arte (ver sección 1.2). Este método es capaz de procesar cualquier cantidad de bandas espectrales y producir información detallada de detección de cambio, incluyendo una clasificación del tipo de cambio ocurrido. En contrapartida, esta técnica requiere un complejo proceso de búsqueda de umbral, que determina en gran medida la calidad del resultado final. Entre todas las técnicas disponibles, CVA es capaz de describir los datos de salida en forma vectorial, incluyendo la magnitud total de cambio y ángulo de dirección entre dos muestras de diferentes fechas.

3.3.2 Comparación post-clasificación

Esta técnica consiste en clasificar por separado las imágenes multitemporales en mapas temáticos, para luego implementar la comparación de las imágenes clasificadas píxel a píxel. Es indispensable definir las clases adecuadas que se quieren discriminar y tener una buena calidad en las clasificaciones previas. Este método requiere tiempo y experiencia del analista para seleccionar las muestras de entrenamiento en la clasificación supervisada. Su precisión final depende pues de los resultados de la clasificación.

3.3.3 Interpretación visual

En este método se interpreta visualmente el compuesto de colores RGB que puede representar distintas fechas y/o bandas. Así, se identifican las áreas modificadas mediante la interpretación visual de las imágenes superpuestas de diferentes fechas. Se requiere experiencia y conocimiento por parte del analista a la hora de realizar la interpretación. El analista puede incorporar textura, forma, tamaño y patrones en la interpretación visual para tomar una decisión sobre el cambio de LULC. Requiere mucho tiempo, experiencia del analista y no puede proporcionar información de cambio detallada.

3.4 Evaluación de resultados

En el desarrollo de la Tesis los resultados requieren ser evaluados mediante parámetros de calidad, que se introducen en esta sección.

3.4.1 Matriz de confusión

Para la evaluación de los resultados de esta Tesis se emplea la técnica clásica de la matriz de confusión [224,265–267]. Es el modo más extendido y reconocido para evaluar los resultados de clasificación y de cambio por la comunidad científica. Gracias a su análisis, se obtiene el error de comisión y el error de omisión, que se detallan a continuación. La tabla 3.2 representa una matriz de confusión genérica y sus parámetros derivados.

Tabla 3.2: Los parámetros de la matriz de confusión.

Clases		Referencia					Total marginal	Error de comisión
		Clase ₁	Clase ₂	Clase ₃	...	Clase _n		
Imagen clasificada	Clase ₁	X_{11}	X_{12}	X_{13}	...	X_{1n}	X_{1+}	EC_{1+}
	Clase ₂	X_{21}	X_{22}	X_{23}	...	X_{2n}	X_{2+}	EC_{2+}
	Clase ₃	X_{31}	X_{32}	X_{33}	...	X_{3n}	X_{3+}	EC_{3+}

	Clase _n	X_{n1}	X_{n2}	X_{n3}	...	X_{nn}	X_{n+}	EC_{n+}
	Total marginal	X_{+1}	X_{+2}	X_{+3}	...	X_{+n}	N	
Error de omisión	EO_{+1}	EO_{+2}	EO_{+3}	...	EO_{+n}			

1. El error de comisión caracteriza a píxeles que pertenecen a otra clase y que están etiquetados como pertenecientes a la clase de interés [265,266]. Los errores de comisión se muestran en las filas de la matriz de confusión. En el ejemplo de matriz de confusión, la $Clase_1$ tiene un total de X_{1+} píxeles donde X_{11} píxeles se clasifican correctamente y $X_{1+}-X_{11}$ píxeles se clasifican incorrectamente como $Clase_1$ ($X_{1+}-X_{11}$ es la suma de todas las demás clases en la fila $Clase_1$ de la matriz de confusión). La proporción del número de píxeles clasificados incorrectamente del total de píxeles en la clase de set de referencia conforma el error de comisión. Para la $Clase_1$, el error de comisión es $(X_{1+}-X_{11})/X_{1+}$. El error de comisión se calcula así con la siguiente formula:

$$EC_{n+} = \frac{X_{n+} - X_{nn}}{X_{n+}} \quad (3.9)$$

donde X_{n+} es el total marginal de la fila n y X_{nn} es la entrada de la diagonal para la clase n .

2. El error de omisión caracteriza a píxeles que pertenecen en realidad a la clase de interés, pero que el método de clasificación no los ha clasificado en dicha clase [265, 266]. Los errores de omisión se muestran en las columnas de la matriz de confusión. En el ejemplo de matriz de confusión, la $Clase_1$ tiene un total de X_{+1} píxeles verdaderos donde X_{11} píxeles se clasifican correctamente y $X_{+1}-X_{11}$ píxeles verdaderos están clasificados incorrectamente, donde $(X_{+1}-X_{11})$ es la suma de todas las otras clases en la columna $Clase_1$ de la matriz de confusión). La proporción del número de píxeles clasificados incorrectamente en el total de píxeles en la clase del set de referencia forma un error de omisión. Para la $Clase_1$, el error de omisión es $(X_{+1}-X_{11})/X_{+1}$. El error de omisión se calcula entonces con la formula 3.10:

$$EO_{n+} = \frac{X_{+n} - X_{nn}}{X_{+n}} \quad (3.10)$$

donde X_{+n} es el total marginal de la columna n y X_{nn} es la entrada de la diagonal para la clase n .

3.4.1.1 Coeficiente kappa y precisión global

Los índices precisión global (PG) y coeficiente kappa (CK) son los parámetros que más frecuentemente se emplean para reflejar el logro de precisión de una matriz de confusión. La tabla 3.2 contiene la matriz de confusión empleada en este ejemplo para definir el PG y CK. La PG es la relación entre la suma de las entradas diagonales y el número total de muestras comparadas N [214, 267]:

$$PG = \frac{\sum_{i=1}^n X_{ii}}{N}, \quad (3.11)$$

donde X_{ii} es la entrada diagonal de la clase i y n es el número de clases. El coeficiente kappa se define como [214, 267]:

$$CK = \frac{PG - P_e}{1 - P_e}, \quad (3.12)$$

donde P_e es el acuerdo de estimación de oportunidad:

$$P_e = \frac{\sum_{i=1}^n X_{i+} \cdot X_{+i}}{N^2}, \quad (3.13)$$

donde X_{i+} es el total marginal de la fila i y X_{+i} es el total marginal de la columna i .

3.4.2 Matriz de transición e índices de cambio

Para definir los índices de cambio nos basamos en las tablas 3.3 y 3.4, donde m_{n1} y m_{n+} son los porcentajes totales de la clase n en las fechas t_1 y t_2 , respectivamente. G_T representa la ganancia total y L_T la pérdida total. El índice m_T indica la persistencia total, y C_T , S_T , D_T representan el cambio total, el swap y el cambio neto, respectivamente. Las entradas en la diagonal indican persistencia y las entradas fuera de la diagonal indican una transición de la clase i a una clase diferente j [226, 267, 268].

Tabla 3.3: Detalle de una matriz de transición entre las fechas t_1 y t_2 en (%).

$t_1 - t_2$	Clase ₁	Clase ₂	Clase ₃	...	Clase _n	Total t_2	Ganancia
Clase ₁	m_{11}	m_{12}	m_{13}	...	m_{1n}	m_{1+}	G_1
Clase ₂	m_{21}	m_{22}	m_{23}	...	m_{2n}	m_{2+}	G_2
Clase ₃	m_{31}	m_{32}	m_{33}	...	m_{3n}	m_{3+}	G_3
...
Clase _n	m_{n1}	m_{n2}	m_{n3}	...	m_{nn}	m_{n+}	G_n
Total t_1	m_{+1}	m_{+2}	m_{+3}	...	m_{+n}	100	G_T
Pérdida	L_1	L_2	L_3	...	L_n	L_T	

Tabla 3.4: Los índices de la matriz de transición en (%).

Clases	Total en t_1	Total en t_2	Ganancia	Pérdida	Persistencia	Cambio total	Swap	Cambio Neto
Clase ₁	m_{+1}	m_{1+}	G_1	L_1	m_{11}	C_1	S_1	D_1
Clase ₂	m_{+2}	m_{2+}	G_2	L_2	m_{22}	C_2	S_2	D_2
Clase ₃	m_{+3}	m_{3+}	G_3	L_3	m_{33}	C_3	S_3	D_3
...
Clase _n	m_{+n}	m_{n+}	G_n	L_n	m_{nn}	C_n	S_n	D_n
Total	100	100	G_T	L_T	m_T	C_T	S_T	D_T

- **Persistencia:** La persistencia representa los píxeles que permanecen en la misma clase para las dos fechas de referencia [226, 268]. En la tabla 3.3 las entradas en la diagonal indican la persistencia de cada clase, por tanto m_{ii} es la persistencia de la clase i .
- **Ganancia:** Llamamos ganancia de la clase i , a lo que esta clase i gana de otras clases. La ganancia se distribuye en cada fila con la exclusión de las entradas de la diagonal, así se calcula como la diferencia entre el total de la fila i y la persistencia de la clase i [226, 268]:

$$G_i = m_{i+} - m_{ii} \quad (3.14)$$

- **Pérdida:** En la tabla 3.3, la columna de pérdidas muestra la distribución de clases destinatarias de la clase i original entre las fechas t_1 y t_2 . De este modo, la pérdida se calcula con la diferencia entre los totales de la columna y su persistencia [226,268]:

$$L_i = m_{+i} - m_{ii} \quad (3.15)$$

- **Swap:** El concepto swap o intercambio se define por el cambio en la situación espacial de los píxeles de la clase, aunque en conjunto el porcentaje de la clase sea el mismo. La ecuación 3.16 describe que el swap S_i para cada clase i es dos veces el mínimo entre la ganancia y la pérdida [226,268].

$$S_i = 2 \cdot \min(m_{i+} - m_{ii}, m_{+i} - m_{ii}) \quad (3.16)$$

- **Cambio neto:** El cambio neto de una clase es el valor absoluto de la diferencia entre ganancia y pérdida. El cambio neto D_i para la clase i se define como el máximo de la ganancia y la pérdida menos el mínimo entre la ganancia y la pérdida [226,268].

$$D_i = \max(m_{i+} - m_{ii}, m_{+i} - m_{ii}) - \min(m_{i+} - m_{ii}, m_{+i} - m_{ii}), \quad (3.17)$$

$$D_i = |m_{+i} - m_{i+}| \quad (3.18)$$

Si el cambio neto es cero (implicando que la ganancia es igual a la pérdida), entonces el swap es el doble de la pérdida o ganancia.

- **Cambio total:** El cambio total de cada clase se puede expresar con la suma de las ganancias y pérdidas o con la suma del cambio neto y el swap [226,268].

$$C_i = G_i + L_i \quad (3.19)$$

$$C_i = D_i + S_i \quad (3.20)$$

- **Relación ganancia a persistencia:** La relación ganancia a persistencia g_p es un buen indicador para medir el cambio [268]. Si es mayor que 1 indica que la clase experimenta más ganancia que persistencia.

$$g_{pi} = \frac{G_i}{m_{ii}} \quad (3.21)$$

- **Relación pérdida a persistencia:** La relación pérdida a persistencia l_p indica la

vulnerabilidad de las clases al cambio [268]. Los valores de l_p superiores de 1 indican una mayor tendencia de las coberturas de tierra a la transición a otras clases de tierra que la persistencia en su clase.

$$l_{pi} = \frac{L_i}{m_{ii}} \quad (3.22)$$

- **Relación cambio neto a la persistencia:** La relación cambio neto a persistencia n_p evalúa la probabilidad de cambio general de una clase durante el período de estudio [268]. El índice del cambio neto a la persistencia n_p se obtiene con la diferencia entre la ganancia a la persistencia y la pérdida a la persistencia.

$$n_{pi} = |g_{pi} - l_{pi}| \quad (3.23)$$

Una vez se han presentado las herramientas metodológicas básicas, se van a presentar los estudios en los que se hace uso de ellas, dejando la descripción de las técnicas de los algoritmos más avanzados para capítulos posteriores.

Detección con vectores CVA

En este capítulo se introduce la técnica de detección de cambio con vectores en dos áreas de estudio para estudiar sus resultados en distintos tipos de escenario. Una zona, empleada con anterioridad en la literatura, es muy dinámica, y en la otra, correspondiente al país de interés, se aprecia poco cambio. Aquí se identifican las etapas clave de esta metodología, de cara a seleccionar el método más adecuado en el estudio de desertificación posterior.

4.1 Introducción

Se estudia la detección de cambio en dos áreas diferentes completamente, una zona predominantemente urbana muy dinámica y otra centrada en el país de interés (Argelia) con poco cambio. Tal y como se ha descrito con anterioridad, existen una gran variedad de métodos para la detección de cambios. Tomando los resultados presentados en la prensa científico-técnica como punto de partida en aplicaciones semejantes, en esta Tesis se toma como punto de partida el método CVA, la comparación post-clasificación y la interpretación visual.

El Objetivo 1 de esta Tesis, descrito en la sección 1.1, consiste en obtener un mapa de detección de cambio en el Distrito de Shunyi (Pekín, China) y en Aïn Defla (Argelia) empleando la metodología *Supervised Change Vector Analysis in Posterior probability Space (SCVAPS)*. La técnica propuesta es una versión modificada del CVA clásico. Se aplica en la misma región en la que se propuso en la prensa científica para validar los resultados. Se hace un estudio comparativo de los métodos de clasificación por píxel, y se selecciona el clasificador supervisado de MLC porque proporciona los mejores resultados de clasificación. Se propone el método DFPS para la determinación del umbral más adecuado. Este

método de detección incluye dos pasos, el primer paso implementa el algoritmo DFPS para generar una imagen binaria cambio/no-cambio y el segundo paso utiliza el producto escalar para obtener el mapa de cambios discriminados. La técnica propuesta SCVAPS para la detección de cambio se evalúa en dos áreas de estudio, en el Distrito de Shunyi (Pekín, China) utilizando un par de imágenes Landsat-7 y en la ciudad de Aïn Defla (Argelia) usando un par de imágenes de Landsat-5. La evaluación final se obtiene mediante la precisión global de la etiqueta cambio/no-cambio de los píxeles, el coeficiente kappa, los mapas de discriminación de cambio y las matrices de transición y de cambio.

4.2 Áreas de estudio

Las imágenes de las áreas de estudio seleccionadas han sido adquiridas del programa Landsat con diferentes sensores, y están disponibles gratuitamente en el archivo del USGS en [269]. Las imágenes del área de Pekín (China) fueron adquiridas por el sensor Landsat-7 ETM+. Todas las bandas fueron utilizadas en la metodología, excepto del infrarrojo térmico. El área de estudio esta situada fuera de la franja de datos no válidos de ETM+ (debido a fallo en *Scan Line Corrector (SLC)*). Si estuviera afectada por este problema, se podría corregir mediante la técnica *gapfill*. El área elegida se encuentra en el distrito de Shunyi, y se encuentra desde la latitud terrestre 40,04°N a 40,20°N y desde la longitud terrestre 116,53°E hasta 116,68°E. Las características de la imagen y las fechas de adquisición se muestran en la tabla 4.1. Las imágenes seleccionadas se obtuvieron en el mismo mes para reducir la variación estacional. Una sub-área con 560×442 píxeles se seleccionó para un estudio en profundidad. Cubre un área total igual a 222,77 km². Esta área fue utilizada en la literatura para presentar la metodología original de CVA en [99]. Se puede destacar que tiene una alta dinámica por actividad humana gracias a la construcción y destrucción de edificios para extender la ciudad y el aeropuerto. La figura 4.1 muestra el mapa general y la ubicación de la sub-área de estudio está representada en la figura 4.2.

Tabla 4.1: Características de las imágenes del área de estudio en Pekín, China.

Fecha de Adquisición	Sensor ID,N°	Modo del sensor	Path/ Row	Versión LPGS	Tipo de dato	Azimut solar	Elevación solar
30-04-2000	ETM, 7	SAM	123/032	12.3.1	L1T	137,97	58,50
10-04-2010	ETM, 7	Bumper	123/032	12.5.0	L1T	142,46	51,94

El segundo conjunto de datos utilizado en este trabajo consiste en dos imágenes adquiridas por el sensor Landsat-5 TM en la región de Aïn Defla (Argelia). Se elige esta zona de Aïn Defla porque se quiere observar la capacidad de la metodología para abordar cambio de origen natural, ya esta zona está gravemente afectada por incendios forestales (bosque de Zaccar), ya que en 2008 se vieron afectadas 2300 hectáreas por un

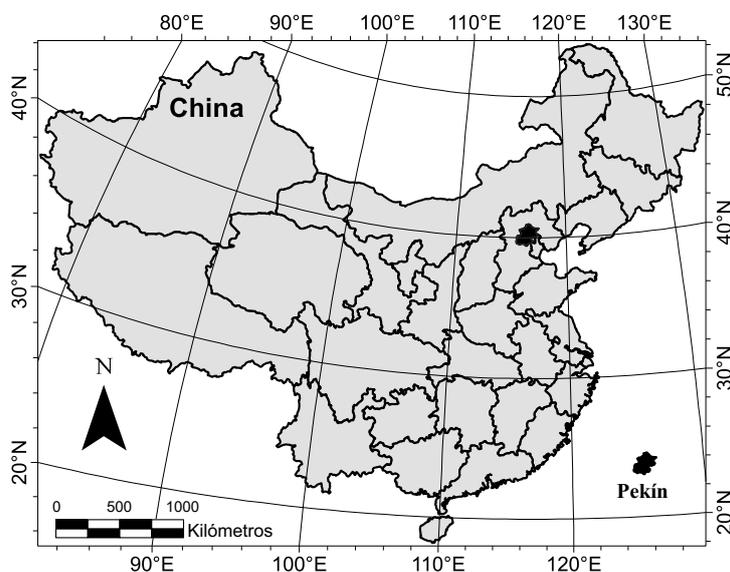


Figura 4.1: Ubicación de la zona de China en el mapa.

grave incendio. Esta zona está clasificada por las agencias competentes como una de las más gravemente amenazadas de Argelia (tiene una vigilancia de primer grado), ya que cada año registra una grave afectación de bosques quemados durante la temporada de verano. Todas las bandas, excepto la del infrarrojo térmico, se usan en esta metodología. El análisis de detección de cambios en un área con cambio natural fue el principal objetivo de selección de esta zona, que por otra parte se asemeja más al tipo de paisaje bajo riesgo de desertificación que se aborda más adelante en la Tesis. Presenta una superficie total igual a $788,18 \text{ km}^2$, ubicada entre una latitud terrestre de $36,13^\circ\text{N}$ y $36,34^\circ\text{N}$ y una longitud terrestre entre $1,98^\circ\text{E}$ y $2,36^\circ\text{E}$. En el estudio, se eligió una sub-área de 775×1130 píxeles, que se muestra en la figura 4.3 y la figura 4.4. La tabla 4.2 presenta más información sobre el conjunto de datos en Argelia y sus características de adquisición.

Tabla 4.2: Características de las imágenes del área de estudio en Aïn Defla, Argelia.

Fecha de Adquisición	Sensor ID, N°	Modo del sensor	Path/ Row	Versión LPGS	Tipo de dato	Azimut solar	Elevación solar
14-06-2002	TM, 5	Bumper	196/035	12.5.0	L1T	111,30	63,40
04-06-2010	TM, 5	Bumper	196/035	12.5.0	L1T	118,23	65,98

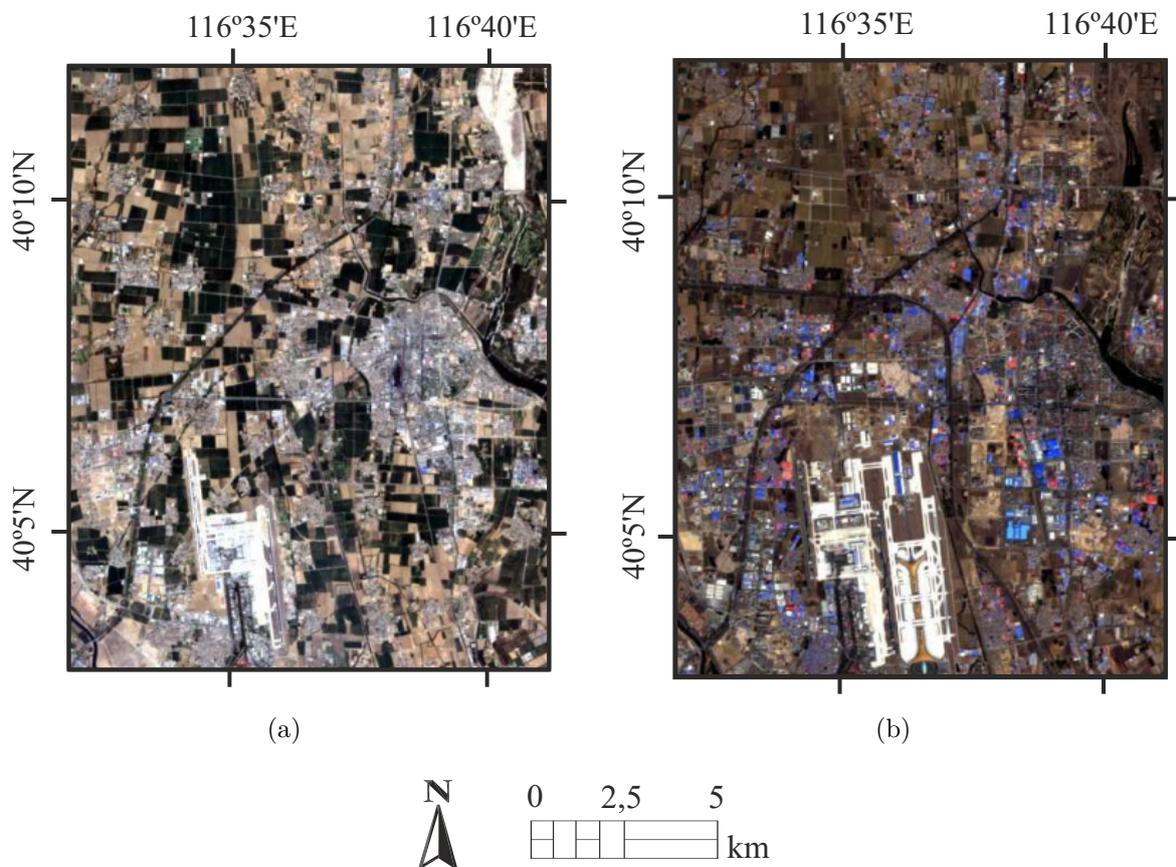


Figura 4.2: El área de estudio de China: imagen de satélite adquirida el 30 de abril de 2000 en (a), e imagen de satélite adquirida el 10 de abril de 2010 en (b).

4.3 Correcciones de imagen

Las imágenes seleccionadas pueden contener cambios en las distintas bandas espectrales de los píxeles causados por varios factores, como la humedad del suelo, las condiciones atmosféricas, la variación del ángulo solar de iluminación, el tipo de sensor y otros parámetros, además de la causa real de detección de cambios. Estos cambios espectrales de píxeles se deben eliminar para hacer que los cambios solo reflejen cambios reales en la superficie. Un factor muy importante en la detección de cambios es asegurarse de que la ubicación de las mismas características de superficie sea coherente. Si la exactitud del co-registro de la imagen es baja, se detectará una gran cantidad de píxeles como cambiados solo por el cambio de ubicación del píxel en la imagen. Por lo tanto, el procesamiento previo de las imágenes satelitales incluye calibración radiométrica, la normalización atmosférica, la corrección geométrica, el registro de imágenes y la rectificación de imágenes.

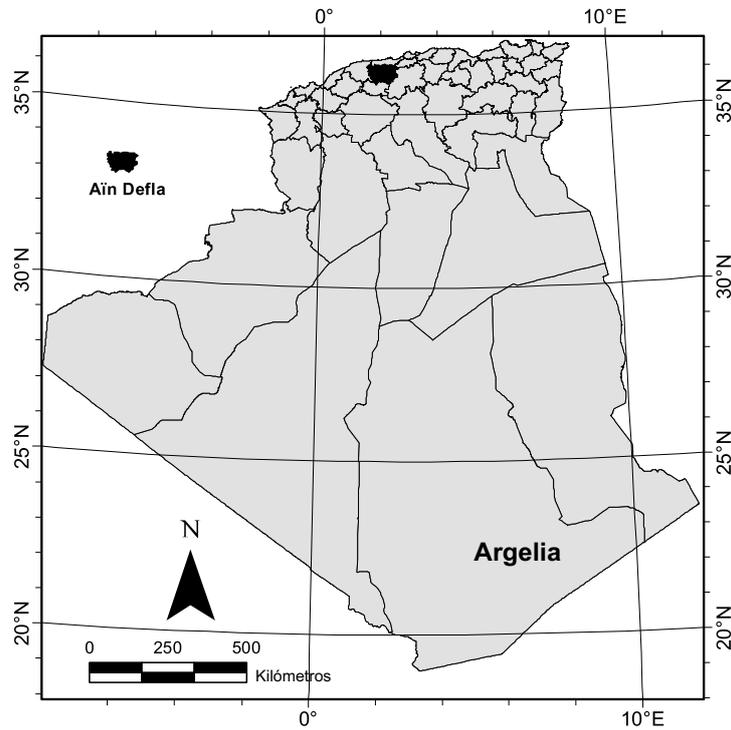


Figura 4.3: Mapa de localización del área de estudio en Aïn Defla (Argelia).

La corrección radiométrica es críticamente necesaria debido a varios factores, como el cambio de los parámetros del tipo de sensor, diferentes ángulos de acimut y de cenit solares y diferentes condiciones atmosféricas de dispersión y absorción [270].

En esta parte, la corrección atmosférica se ha llevado a cabo utilizando el algoritmo DOS y la corrección radiométrica se ha realizado utilizando el algoritmo de corrección Landsat del software ENVI. La corrección geométrica también se aplica para asemejarse a las coordenadas de ubicación de tierra de referencia. Finalmente, el registro de la imagen y la rectificación de la imagen proporcionan la imagen corregida que se usará para el análisis. Después de la rectificación geométrica y el registro imagen a imagen proporcionados por las herramientas ENVI usando 100 puntos de control, se calcula el error cuadrático medio RMSE entre ambas imágenes y es aproximadamente igual a 0,21 y 0,11 píxeles para las sub-áreas representadas en la figura 4.2 y la figura 4.4, respectivamente.

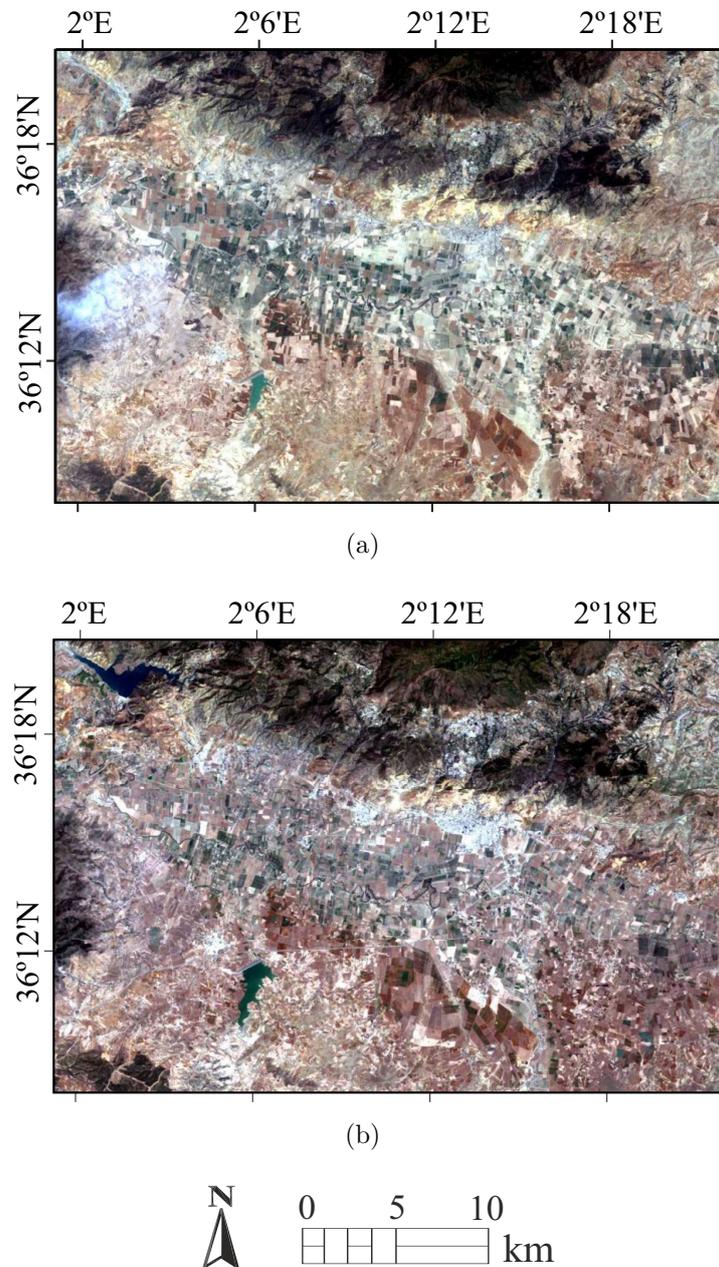


Figura 4.4: Área de estudio en Ain Defla (Argelia): imagen adquirida el 14 de junio de 2002 en (a), e imagen adquirida el 4 de junio de 2010 en (b).

4.4 Detección de cambio

Change Vector Analysis (CVA) es una metodología de detección de cambios que mantiene toda la información relevante de las imágenes clasificadas y por ello permite una interpretación más detallada que otros métodos. Por esta razón es la técnica elegida en este

estudio en primer lugar. La idea global de CVA consiste en calcular los vectores de cambio espectral mediante la sustracción de pares de bandas espectrales [98–101, 116, 121–125]. Un vector de cambio se describe por la magnitud del cambio y el ángulo de cambio entre dos imágenes obtenidas en el momento t_1 y t_2 . Cuando se aplica un umbral a este vector de cambio en función de su magnitud, se determina el posible cambio transcurrido durante el periodo de estudio.

El método *Supervised Change Vector Analysis in Posterior probability Space (SC-VAPS)* descrito en [101] ha sido el punto de partida en esta Tesis. El primer paso en esta metodología es llevar a cabo una clasificación supervisada precisa que proporciona un mapa de probabilidad posterior para cada escena. Para ello, en esta parte del trabajo se usan 5 clases en la leyenda. La tabla 4.3 describe las clases seleccionadas en el proceso de clasificación.

Tabla 4.3: Descripción de las clases usadas.

Clase de cobertura terrestre	Descripción
Urbano	Ciudades, pueblos, carreteras, edificios
Suelo Descubierta (SD)	Suelo agrícola sin cultivo, arena
Agua	Ríos, lagos, embalses
Vegetación No Densa (VND)	Campos de cultivo, pastizales, parcelas
Vegetación Densa (VD)	Bosques, parques

En este estudio se emplean para la clasificación las bandas espectrales b_1 , b_2 , b_3 , b_4 , b_5 y b_7 del instrumento Landsat TM y ETM+. Empleando estas bandas se hace un estudio comparativo entre distintos clasificadores supervisados por píxel. Los clasificadores supervisados requieren un proceso de capacitación del analista, que necesita datos fiables del terreno analizado. Como no se dispone de información adicional de campo, se usa la inspección visual de las imágenes del satélite como referencia para dicho propósito. La cantidad total de píxeles de entrenamiento utilizados en el proceso de clasificación es del 10,74 % del total de la sub-área en China y del 6,02 % del total de la sub-área en Argelia.

El resultado de la clasificación proporciona los vectores de probabilidad posteriores en el dominio espacio-tiempo:

$$H = (h_1, h_2, \dots, h_n), \quad (4.1)$$

$$G = (g_1, g_2, \dots, g_n), \quad (4.2)$$

donde H y G representan los vectores de probabilidad posterior en los momentos t_1 y t_2 , respectivamente. El índice $1, 2, \dots, n$ se refiere a cada una de las clases previamente

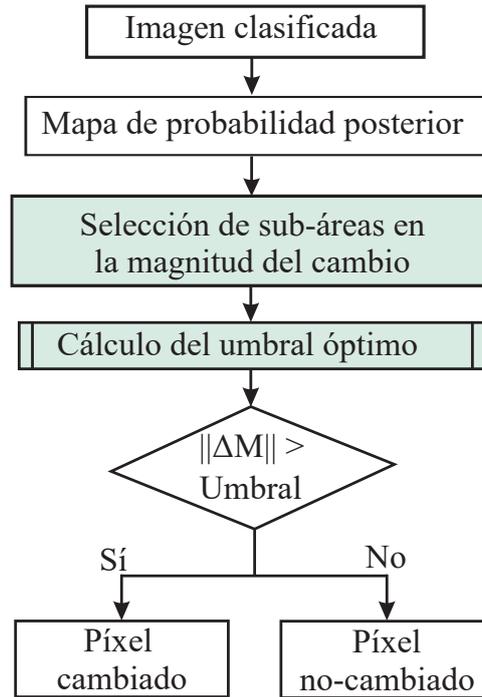


Figura 4.5: Diagrama de flujo de la detección de cambio con el método CVA.

definidas en la leyenda.

El vector de cambio del espacio de probabilidad posterior se define como:

$$\Delta M = G - H, \quad (4.3)$$

donde ΔM es el mapa de diferencia de probabilidad posterior para cada píxel, y también contiene la información del cambio que ha tenido lugar entre las dos imágenes. La magnitud del vector de cambio viene dada por la siguiente expresión:

$$\|\Delta M\| = \left(\sum_{i=1}^n (G_i - H_i)^2 \right)^{1/2}. \quad (4.4)$$

En este contexto, un valor grande para $\|\Delta M\|$ indica una gran posibilidad de cambio de píxel. Sin embargo, si se debe tomar una decisión en el caso de que $\|\Delta M\|$ tome un valor medio, la asignación de la etiqueta de cambio o no-cambio representa una decisión compleja. Por ello una selección del umbral es un paso muy crítico en el procedimiento. La figura 4.5 muestra este procedimiento, donde el paso de selección de umbral óptimo es la etapa que se analizará más a fondo.

4.4.1 Selección de umbral

La etapa de la selección del umbral es uno de los pasos más importantes en el procedimiento CVA para determinar si un píxel ha cambiado o no. En esta parte se emplea un método de determinación de umbral supervisado, que utiliza el algoritmo DFPS descrito en [99]. El método DFPS es una técnica semiautomática para determinar el umbral óptimo, que solo requiere la participación del analista de imágenes durante la selección de muestras de entrenamiento del uso del suelo. Las ventajas de este método se pueden resumir en que, en primer lugar, el umbral óptimo se puede obtener automáticamente, en segundo lugar, con esta técnica se puede controlar de manera efectiva el error de comisión causado por una disminución excesiva del umbral, y en tercer lugar, la eficiencia de la búsqueda se puede mejorar de forma flexible. Aunque este método puede alcanzar un mejor rendimiento en comparación con otros métodos empíricos previos, se debe tener en cuenta que sus resultados dependen de las muestras de entrenamiento, cuya calidad está condicionada por la experiencia y las habilidades del analista.

Este método selecciona el umbral de entrenamiento a partir de muestras que contienen todos los posibles tipos de cambios. Se supone que las muestras caracterizan completamente toda la zona de estudio. Por lo tanto, el umbral que consiga una precisión máxima de detección de cambio dentro de las muestras de entrenamiento será considerado como el umbral óptimo para toda el área de estudio. Los resultados de este método se describen en la sección 4.5. El diagrama de flujo del método DFPS se muestra en la figura 4.6 y sus principales etapas se describen a continuación:

1. Selección de las muestras: en esta fase, es importante asegurarse de que las muestras contienen todas las posibles clases de la leyenda. Primero se calcula la magnitud del cambio $\|\Delta M\|$ a partir de las dos imágenes corregidas y registradas. Luego, algunas muestras de cambio se seleccionan a partir de su magnitud de cambio. Los criterios para seleccionar las muestras son:
 - las muestras deben cubrir la mayor cantidad posible de tipos de cambio. Se toma en cuenta el cambio comparando el contexto y el contenido espectral entre las dos imágenes.
 - las muestras de entrenamiento deben incluir píxeles con cambio.
 - las muestras de entrenamiento deben estar rodeadas por píxeles sin cambio. Se deben usar las imágenes originales y compararlas visualmente con la magnitud del cambio.

El umbral que permite identificar los píxeles cambiados/no-cambiados se obtiene con la determinación del valor óptimo a partir de la imagen del magnitud de cambio

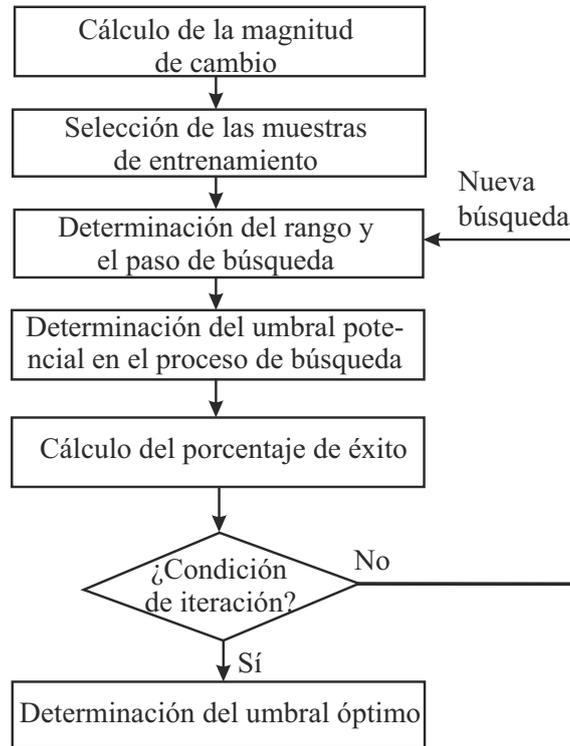


Figura 4.6: Diagrama de flujo del algoritmo *Double-Window Flexible Pace Search (DFPS)*.

con la máxima precisión. Obviamente, a medida que disminuye el umbral de magnitud de cambio, aumentará el número de píxeles de cambio dentro de las muestras de entrenamiento y se mejorará la precisión de la detección de cambio. Sin embargo, debe tenerse en cuenta que la posibilidad de que no haya píxeles de cambio fuera de las muestras de entrenamiento identificadas como píxeles de cambio también aumentaría, lo que llevaría a errores de comisión más elevados. Se busca aquel umbral con el que todos los píxeles dentro de las muestras de entrenamiento se detecten correctamente como píxeles de cambio y se obtenga la mayor precisión en las muestras de entrenamiento, a la vez que se minimize el número de píxeles que se identifican incorrectamente como píxeles de cambio. Para este propósito, se crea un límite externo a través del almacenamiento intermedio en un SIG para cada set de entrenamiento, formando un área doble llamada ventana doble.

2. Determinación del rango y el paso en el proceso de búsqueda: se establece el rango de búsqueda del umbral en la primera iteración con la diferencia entre el valor mínimo $\|\Delta M\|_{min}$ y el valor máximo $\|\Delta M\|_{max}$ de magnitud de cambio siguiendo el proceso propuesto en [99]. El paso en la primera iteración del proceso de búsqueda se define

con la ecuación 4.5:

$$P_1 = \frac{\|\Delta M\|_{max} - \|\Delta M\|_{min}}{m} \quad (4.5)$$

donde m es un número entero positivo, que permite determinar el número de posibles umbrales en cada iteración del proceso de búsqueda y que se puede configurar manualmente. Los posibles umbrales para detectar píxeles de cambio de las muestras de entrenamiento en el primer proceso de búsqueda se darán dentro del rango $[\|\Delta M\|_{min}, \|\Delta M\|_{max}]$ como $\|\Delta M\|_{max} - P_1, \|\Delta M\|_{max} - 2P_1, \dots$. Se debe tener en cuenta que el valor de m introducido manualmente en cada iteración no afecta la eficiencia de búsqueda y los resultados finales. Un valor de m grande aumenta el número de posibles umbrales durante cada iteración, pero disminuye el número de iteraciones tal y como se describe en [99].

3. El porcentaje de éxito: se define para evaluar el rendimiento de cada posible umbral durante el proceso de búsqueda para identificar los píxeles de cambio/no-cambio. El porcentaje de éxito R_k para un posible umbral k se calcula con la ecuación 4.6:

$$R_k = \frac{A_{k1} - A_{k2}}{A_t} \quad (4.6)$$

donde A_{k1} presenta la cantidad de píxeles de cambio detectados dentro de todos los sets de entrenamiento (en las ventanas internas), A_{k2} es el número de píxeles de cambio que se detectan incorrectamente en el límite exterior de todos los sets de entrenamiento (en las ventanas externas) y A_t es la cantidad total de píxeles dentro de todos los sets de entrenamiento (en las ventanas internas). A partir de esta definición, se puede ver que el concepto de doble ventana es útil para controlar el error de comisión causado por umbrales bajos, porque los umbrales bajos aumentan A_{k2} y reducen R_k . Después de obtener todos los R_k para todos los umbrales m_i en una iteración, se identifican los valores máximo R_{max} y mínimo R_{min} de R_k en el intervalo de búsqueda de la iteración. Si no se cumple la condición presentada en el siguiente punto, empieza una nueva iteración de búsqueda dentro del rango $[U_{max} - P_i, U_{max} + P_i]$, y se establece un nuevo paso de búsqueda más pequeño basado en la ecuación 4.5. El valor de U_{max} es el umbral correspondiente a R_{max} y P_i es el valor del paso en la iteración i -ésima en el proceso de búsqueda según [99].

4. Condición para salir de la iteración: el proceso de iteración finalizará cuando se satisfaga la fórmula 4.7:

$$R_{max} - R_{min} \leq \delta \quad (4.7)$$

donde δ es un error aceptable predeterminado. La condición indica que el cambio del paso de búsqueda tiene poca influencia en el resultado de píxeles de cambio/no-

cambio. El umbral U_{max} correspondiente a R_{max} se considera como el umbral óptimo para la detección de cambio.

4.4.2 Discriminación del tipo de cambio

La discriminación de tipo de cambio se usa para identificar el tipo de cambio LULC que ha ocurrido en los píxeles con la etiqueta de cambio en un mapa tal y como se describe en [101]. Se obtiene mediante el análisis del mapa de probabilidad posterior y la comparación radiométrica en píxeles.

La información del cambio que ha ocurrido entre el tiempo t_1 y t_2 se puede obtener de la dirección del vector ΔM . Un píxel puro transformado de la clase a a otra clase b durante un período de tiempo presentaría el siguiente vector de cambio:

$$\Delta P_{ab} = P_b - P_a, \quad (4.8)$$

$$P_z = (p_{z1}, p_{z2}, \dots, p_{zn}), \quad (4.9)$$

$$p_{zi} = \begin{cases} p_{zi} = 1, & \text{si } i = z \\ p_{zi} = 0, & \text{si } i \neq z \end{cases}, \quad (4.10)$$

donde P_z describe el vector de probabilidad posterior de un píxel puro de la clase z . Cuando el ángulo entre el vector real ΔM y el vector teórico ΔP_{ab} es pequeño, entonces el píxel correspondiente probablemente haya cambiado de la clase a a la clase b . Luego, el tipo de cambio se puede determinar fácilmente a partir del producto escalar, buscando el valor máximo para el producto escalar de todas las combinaciones posibles de pares $a - b$:

$$\Delta M \cdot \Delta P_{ab} = \sum_{i=1}^n (\Delta M)_i \cdot (\Delta P_{ab})_i. \quad (4.11)$$

4.5 Clasificación de las imágenes y resultados

El primer estudio consiste en seleccionar el mejor clasificador supervisado por píxel para una detección exitosa del cambio de la tierra en los escenarios bajo test. Se usan diferentes métodos para la clasificación por píxel y se hace una comparación de los resultados obtenidos por todos ellos (ver la sección 3.2.1) para seleccionar el algoritmo más adecuado.

La tabla 4.4 indica los resultados de cada método empleado cuando se analiza la zona de China. El clasificador *Spectral Angle Mapper (SAM)* proporciona los peores resultados,

mientras que los otros métodos dan una precisión global entre 73,94 % y 88,67 % y un coeficiente kappa entre 0,47 y 0,77. El método MLC da mejores resultados en relación con los parámetros PG y CK.

Tabla 4.4: Resultados de los métodos de clasificación en la zona Pekín (China) en 2010.

El clasificador	PG	CK
Distancia mínima	80,65	0,61
Distancia Mahalanobis	73,94	0,47
<i>Spectral Angle Mapper (SAM)</i>	67,18	0,34
<i>Maximum Likelihood Classifier (MLC)</i>	90,71	0,81
SVM lineal	83,63	0,67
SVM polinomio	88,67	0,77
SVM función de base radial	87,89	0,76
SVM sigmoideo	77,46	0,55

Las tablas 4.5 y 4.6 presentan las matrices de confusión que validan el clasificador MLC seleccionado. El número total de píxeles usado para la validación de clasificación es de 5578 píxeles para el área de China y 6783 píxeles para Argelia. En el caso de la clasificación MLC del año 2010 en China y Argelia, se ha registrado una precisión global de 90,71 % y 94,84 %, respectivamente. El coeficiente kappa obtenido ha sido igual a 0,81 y a 0,93, respectivamente. Los errores comisión y omisión están bien balanceados en ambas áreas. Con estos buenos resultados, se valida el clasificador MLC por píxel y se emplea a continuación para clasificar todas las escenas del estudio y realizar la detección de cambio en las dos zonas.

Tabla 4.5: Matriz de confusión para la validación de clasificación MLC en el área de China en 2010.

Clase		Suelo verdadero (píxeles)					Error de comisión
		Urbano	VD	Agua	SD	VND	
Imagen clasificada	Urbano	1232	9	0	7	0	1,28 %
	VD	57	1362	5	0	26	6,07 %
	Agua	20	12	68	0	1	32,67 %
	SD	17	26	0	1290	1	3,30 %
	VND	266	36	2	33	1108	23,32 %
	Error de omisión	22,61 %	5,74 %	9,33 %	3,01 %	2,46 %	
Precisión global 90,71 %, coeficiente kappa 0,81							

Tabla 4.6: Matriz de confusión para la validación de clasificación MLC en el área de Argelia en 2010.

Clase		Suelo verdadero (píxeles)					Error de comisión
		Urbano	VD	Agua	SD	VND	
Imagen clasificada	Urbano	1633	4	0	60	13	4,50 %
	VD	5	1587	13	19	34	4,28 %
	Agua	3	22	104	3	1	21,80 %
	SD	21	5	0	1501	27	3,41 %
	VND	58	62	0	0	1608	6,94 %
	Error de omisión	5,06 %	5,54 %	11,11 %	5,18 %	4,46 %	
Precisión global 94,84 %, coeficiente kappa 0,93							

La metodología seleccionada se aplica a los dos conjuntos de datos correspondientes a China y Argelia. Las imágenes de las clasificaciones obtenidas a partir de los vectores de probabilidad posterior H para el tiempo t_1 y G para el tiempo t_2 se muestran en la figura 4.7 y figura 4.8 para las sub-áreas de China y Argelia, respectivamente. Son los resultados obtenidos por el clasificador MLC, que emplea las bandas b_1, b_2, b_3, b_4, b_5 y b_7 . Se usan las clases: urbana, suelo descubierto, agua, vegetación no densa, y vegetación densa. Este rango simplificado de clases permite que la metodología obtenga un mapa de clasificación muy preciso incluso con una baja cantidad de píxeles de entrenamiento y es adecuado para la detección de desertificación, que es el fin último del trabajo. La cantidad total de píxeles de entrenamiento utilizados en el proceso de clasificación es del 10,74 % del total en China y del 6,02 % del total en Argelia. Se aprecia una gran cantidad de píxeles cambiados en China debido al rápido crecimiento económico de la zona. En contraposición, la escena argelina muestra escasos cambios en la vegetación y en la capa del agua de origen natural, tal y como se esperaba.

El algoritmo DFPS clásico descrito en la sección 4.4.1 calcula el umbral óptimo para identificar los píxeles cambiados y no-cambiados buscando el mejor porcentaje de éxito final. Sin embargo, los criterios de selección de las muestras de entrenamiento del algoritmo son muy complejos. El método DFPS se basa en la búsqueda del umbral comparando cuatro ventanas dobles de muestras especialmente escogidas de dos imágenes tomadas en diferentes momentos t_1 y t_2 y que cubren un total de 5028 píxeles cambiados y 6119 píxeles no-cambiados. Comparando con el procedimiento presentado en la literatura en [101], en aquella ocasión el total de las ventanas dobles empleado corresponde a 195 píxeles no-cambiados y 211 píxeles cambiados.

En el área de China, el proceso de búsqueda del umbral empieza en el rango $[0,$

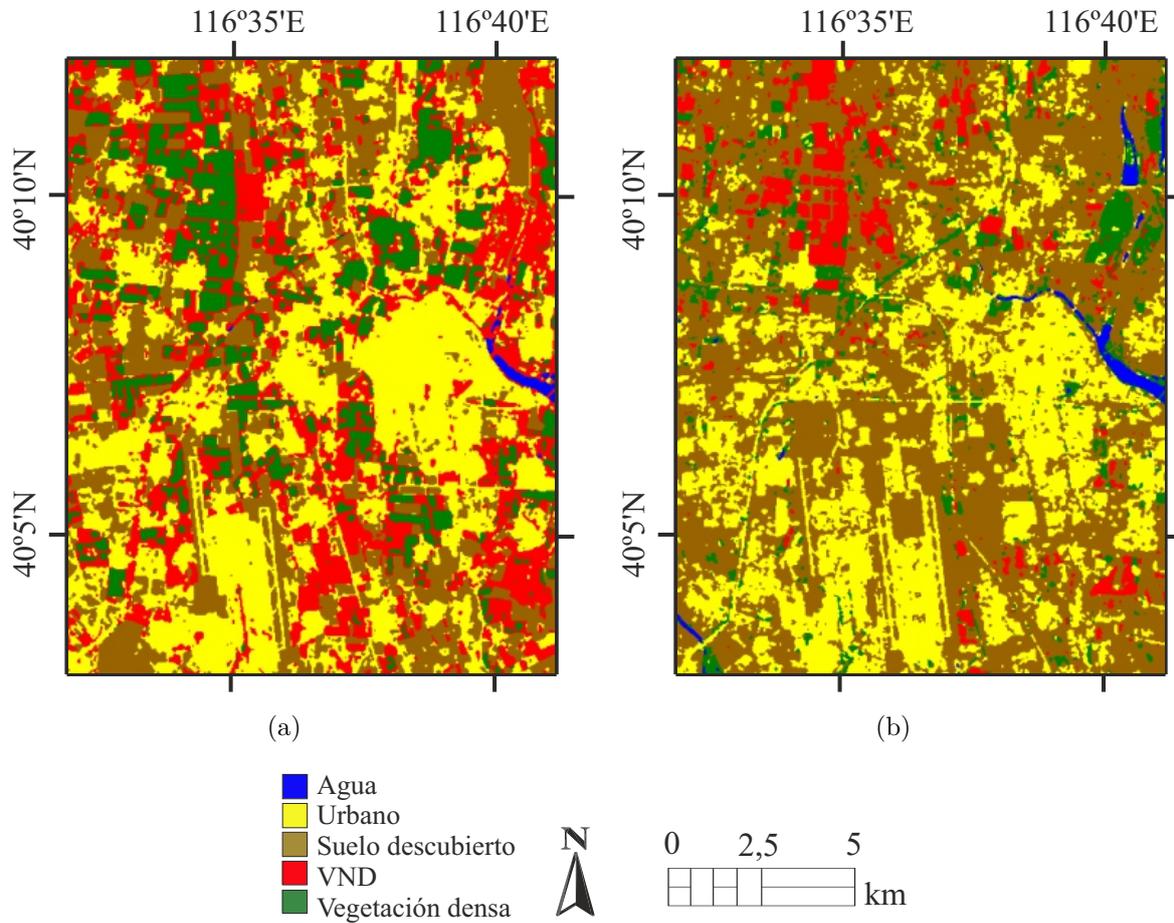


Figura 4.7: Clasificación de la región de China: (a) datos adquiridos el 30 de abril de 2000, y (b) datos adquiridos el 10 de abril de 2010.

5,380] con un primer paso de 0,5380. Los resultados indican que el valor 1,0087 tiene un porcentaje de éxito de 70,985 %. La tabla 4.7 muestra el progreso de búsqueda de umbral con el método DFPS dentro el rango $[0, 5,380]$ con los pasos 0,5380, 0,1793, 0,0448, 0,0224. Este proceso necesita 31 evaluaciones del parámetro de calidad en todas las muestras para lograr el umbral óptimo.

En el área de Argelia, el proceso de búsqueda comienza en el rango $[0, 6,4031]$ con un paso de 0,6403 en la primera iteración. Como resultado, el umbral obtenido tiene un valor de 3,2015 con un porcentaje de éxito del 64,268 %. La tabla 4.8 presenta el progreso del proceso de búsqueda en el rango anterior con los pasos 0,6403, 0,2134, 0,0711 y 0,0355. El proceso de búsqueda necesita 29 evaluaciones del parámetro de calidad en todas las ventanas. El umbral óptimo para decidir si un píxel ha cambiado o no en el área de China y Argelia es de 1,0087 y 3,2015 respectivamente, utilizando la técnica DFPS.

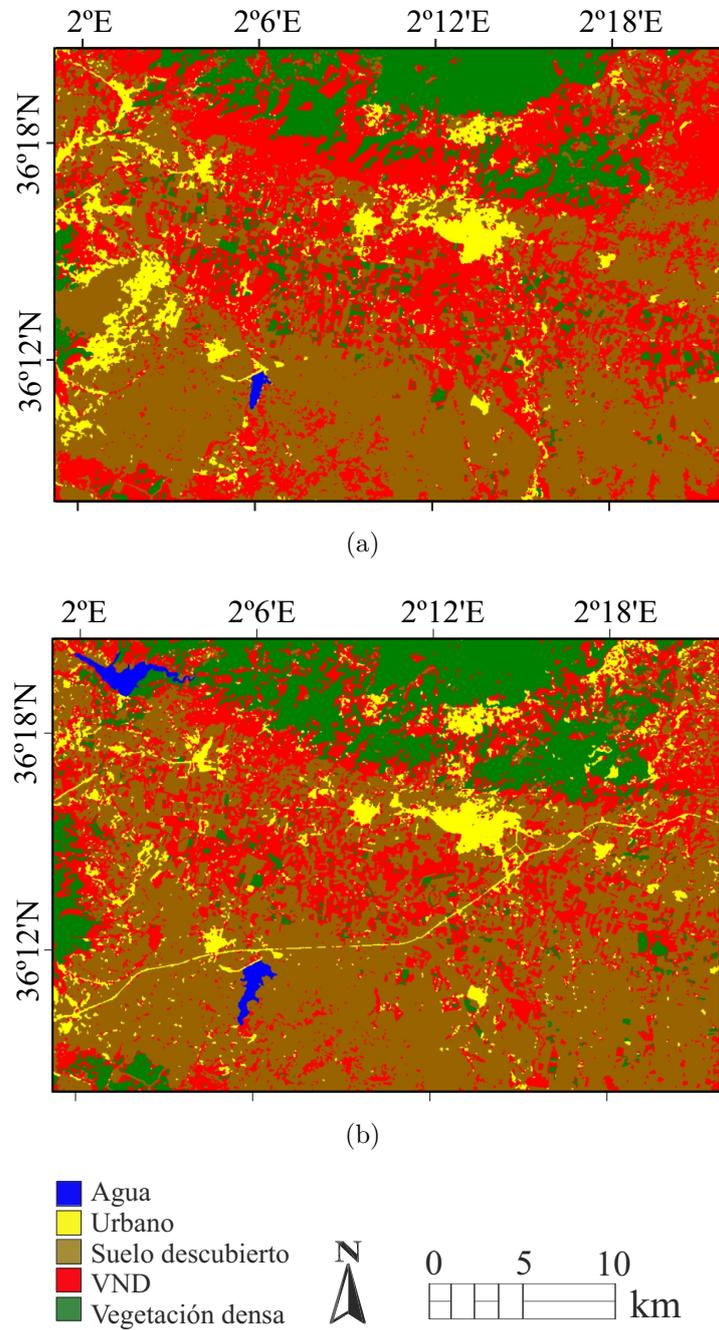


Figura 4.8: Clasificación de la región de Aïn Defla: datos adquiridos el 14 de junio de 2002 en (a), y datos adquiridos el 4 de junio de 2010 en (b).

Tabla 4.7: Resultados de la selección de umbral con el método *Double-Window Flexible Pace Search (DFPS)* en el área de China.

Rango = [5,380,0] Paso = 0,5380		Rango = [1,614,0,538] Paso = 0,1793		Rango = [1,2553,0,8966] Paso = 0,0448		Rango = [1,076,0,9863] Paso = 0,0224	
Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito
5,3800	39,028 %	1,6140	57,326 %	1,2553	66,327 %	1,0760	69,519 %
4,8420	43,857 %	1,4346	60,147 %	1,2105	67,503 %	1,0535	70,057 %
4,3040	44,628 %	1,2553	66,327 %	1,1656	68,651 %	1,0311	70,430 %
3,7660	47,964 %	1,0760	69,519 %	1,1208	69,308 %	1,0087	70,985 %
3,2280	48,568 %	0,8966	68,848 %	1,0760	69,519 %	0,9863	69,810 %
2,6900	52,179 %	0,7173	67,157 %	1,0311	70,430 %		
2,1520	52,957 %	0,5380	64,847 %	0,9863	69,810 %		
1,6140	57,326 %			0,9415	69,127 %		
1,0760	69,519 %			0,8966	68,848 %		
0,5380	64,847 %						

Tabla 4.8: Resultados de la selección de umbral con el método *Double-Window Flexible Pace Search (DFPS)* en el área de Argelia.

Rango = [6,4031,0] Paso = 0,6403		Rango = [3,8418,2,5612] Paso = 0,2134		Rango = [3,4149,2,9881] Paso = 0,0711		Rango = [3,2726,3,1304] Paso = 0,0355	
Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito
6,4031	30,072 %	3,8418	59,139 %	3,4149	62,981 %	3,2726	64,123 %
5,7627	39,177 %	3,6284	61,737 %	3,3438	63,360 %	3,2371	64,201 %
5,1224	43,396 %	3,4149	62,981 %	3,2726	64,123 %	3,2015	64,268 %
4,4821	51,285 %	3,2015	64,268 %	3,2015	64,268 %	3,1659	64,222 %
3,8418	59,139 %	2,9881	63,544 %	3,1304	64,178 %	3,1304	64,178 %
3,2015	64,268 %	2,7746	62,638 %	3,0592	64,020 %		
2,5612	61,107 %	2,5612	61,107 %	2,9881	63,544 %		
1,9209	56,964 %						
1,2806	60,282 %						
0,6403	11,137 %						

Para evaluar la calidad de los resultados de detección de cambio de la metodología SCVAPS propuesta, se calcula la precisión global y el coeficiente kappa para las escenas escogidas, al comparar los resultados con un conjunto de datos de referencia independientes. Este conjunto de datos de validación utilizado se obtiene mediante inspección visual y lógicamente no coincide con los datos de entrenamiento, con el fin de obtener una evaluación de la calidad justa. La matriz de confusión de los datos de cambio dados por SCVAPS en la región de China se muestra en la tabla 4.9, empleando 25587 píxeles de muestra. El conjunto de datos de validación en China es del 10,33 % del total de la zona. El método propuesto logra excelentes resultados con un coeficiente kappa de 0,837 y una precisión global de 91,851 %. El error de comisión obtenido es del 7,61 % para los píxeles no cambiados y del 8,70 % para los píxeles cambiados, mientras que el error de omisión es del 8,47 % para los píxeles no cambiados y del 7,82 % para los píxeles cambiados.

Este resultado de detección de cambio se compara con los resultados presentados en la literatura en [101] y la comparación indica que el método propuesto proporciona excelentes resultados, teniendo en cuenta que las fechas del estudio son diferentes (30 de abril 2000 y 25 de julio 2005), la imagen de validación del estudio [101] es también diferente (SPOT), y que la leyenda que se emplea es más reducida (4 clases en [101]). El estudio con metodología semejante en [101] obtuvo un coeficiente kappa de 0,877 y una precisión global de 93,8 %. Por lo tanto, el método se valida puesto que da resultados semejantes a la literatura en condiciones parecidas de comparación y se justifica como punto de partida para analizar otras regiones con pocos cambios de la superficie terrestre y diferentes características.

Tabla 4.9: Matriz de confusión cambio/no-cambio para la zona de China.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	11922	982	12904	7,61 %
	Píxeles cambiados	1103	11580	12683	8,70 %
	Total	13025	12562	25587	
	Error de omisión	8,47 %	7,82 %		
Precisión global 91,851 %, coeficiente kappa 0,837					

Una vez que se ha validado la metodología, la tabla 4.10 muestra la matriz de confusión de píxeles cambiados/no-cambiados que se obtiene en la zona de Argelia, que contiene 42539 píxeles. El conjunto de datos de referencia para construir la matriz de

Tabla 4.10: Matriz de confusión cambio/no-cambio para la zona de Argelia.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	18903	1289	20192	6,38 %
	Píxeles cambiados	1280	21067	22347	5,73 %
	Total	20183	22356	42539	
	Error de omisión	6,34 %	5,77 %		
Precisión global 93,961 %, coeficiente kappa 0,878					

confusión es igual al 4,86 % del total del área de estudio. El coeficiente kappa obtenido es igual a 0,878 y la precisión total es del 93,961 %. Los errores de comisión para los píxeles no cambiados es de 6,38 % y para los píxeles cambiados es igual a 5,73 %. Estos resultados muestran el éxito de la metodología para detección de cambios en las dos regiones seleccionadas utilizando datos de Landsat y las 5 clases definidas en la leyenda. El coeficiente kappa está claramente por encima de 0,7 y los errores de omisión y comisión de los píxeles modificados y no modificados están bien balanceados en ambas zonas de prueba, en tanto a los errores de omisión se registra 6,34 % para los píxeles no cambiados y 5,77 % para los píxeles cambiados.

Los mapas de cambio total obtenidos con el algoritmo SCVAPS se muestran en la figura 4.9 y la figura 4.10 para la región de China y la región de Argelia, respectivamente. El color rojo representa los píxeles cambiados en ambas áreas de estudio. El resultado obtenido está condicionado fuertemente por la etapa de búsqueda de umbral mediante el método DFPS. Así, estos mapas muestran información de tipo binario porque solo se decide si ha ocurrido un cambio en la superficie de la tierra. El siguiente paso es la discriminación del cambio, que permite identificar el tipo de cambio que ha ocurrido entre las clases y que aporta un valor mayor al usuario final. Se emplea la técnica de la discriminación del tipo de cambio mediante la búsqueda del valor máximo del producto escalar de todas las posibles combinaciones entre las clases.

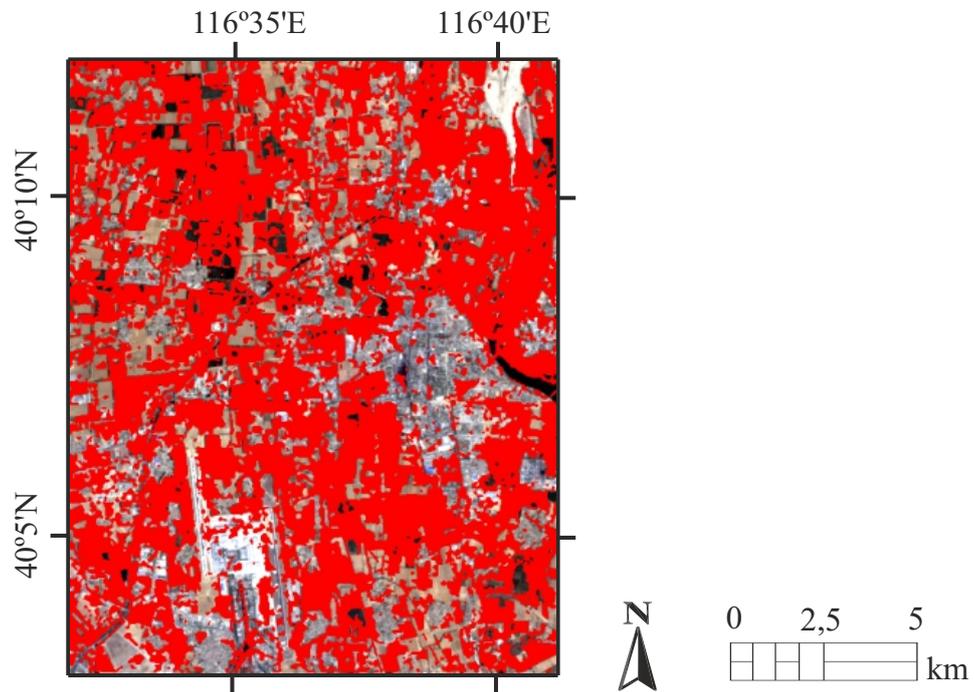


Figura 4.9: Mapa de cambio en la sub-área de China.

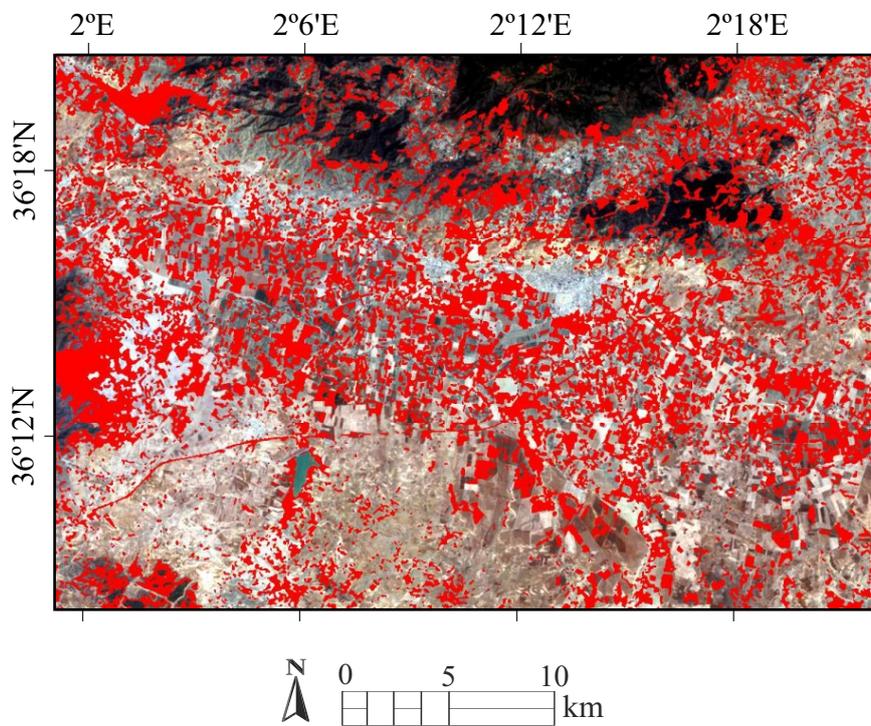


Figura 4.10: Mapa de cambio en Argelia. Los píxeles en rojo representan las áreas modificadas.

De esta forma, se obtienen las figuras 4.11 y 4.12 que representan cada tipo de cambio en China y Argelia, respectivamente. El cambio más importante en la zona de China es el que ocurre desde la clase urbana a la clase suelo descubierto, con un porcentaje del 15,82 %, y el menos importante es desde la clase agua a la clase vegetación densa, con un 0,03 %. Mientras que, para el área de Argelia, el cambio más notable es de la clase vegetación no densa a la clase suelo descubierto, con un 11,03 %, y el cambio menor es el de la clase vegetación densa a la clase agua, con el 0,01 %.

En el caso de China, se observa que existe mucho cambio debido al cambio del uso de la tierra por parte del hombre. Esto es así porque la zona de Pekín es muy cambiante y cada año se modifica en gran medida debido a su planificación y ordenación territorial. Este efecto podría evaluarse fácilmente mediante el uso de la metodología propuesta, aunque el fin último de la Tesis es la aplicación de la metodología en zonas áridas de Argelia.

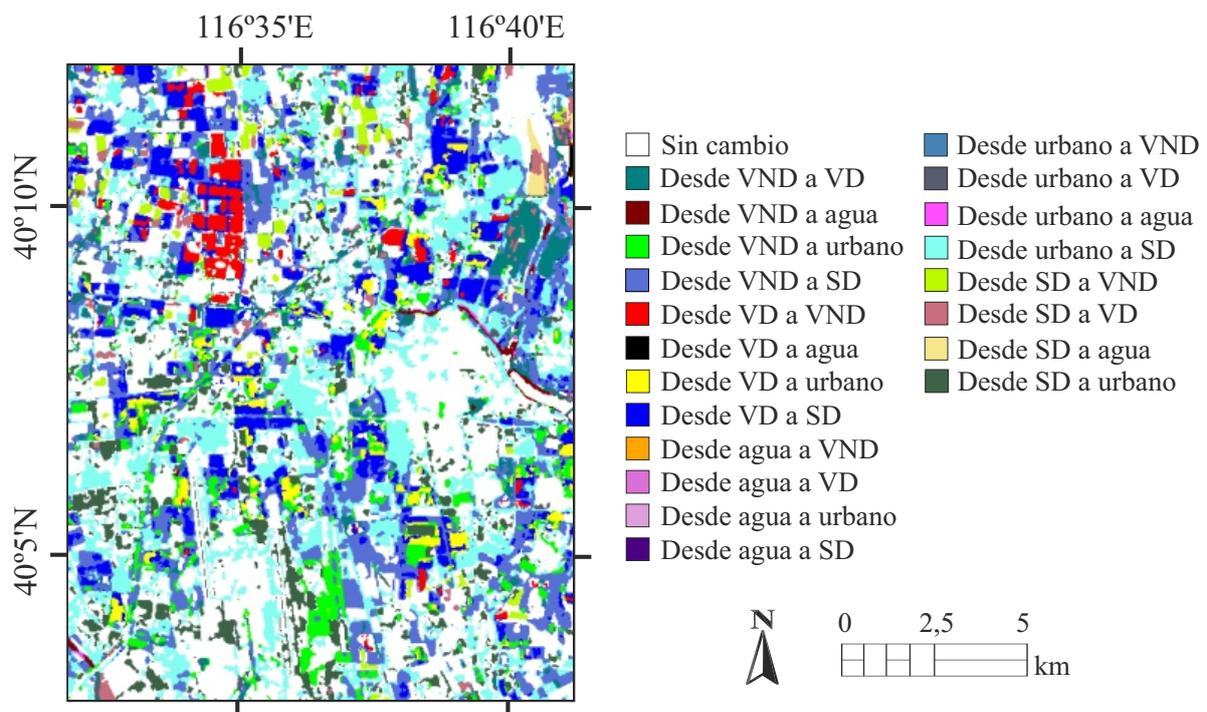


Figura 4.11: Discriminación del cambio en la sub-área de China.

En el área de Argelia, una gran cantidad de píxeles se etiquetan como cambiados debido a la actividad humana y a las diferentes condiciones climáticas que afectan a esta zona, sobre todo en verano. El cambio de la clase vegetación no densa a suelo descubierto es causada sobre todo por incendios forestales, que suelen afectar cada año esta zona. También se aprecian cambios urbanos, debido a la construcción de nuevos edificios. Los

cambios en áreas de vegetación fueron causados por la replantación de nuevos árboles en áreas montañosas y este hecho también está relacionado con la reducción de la vegetación no densa.

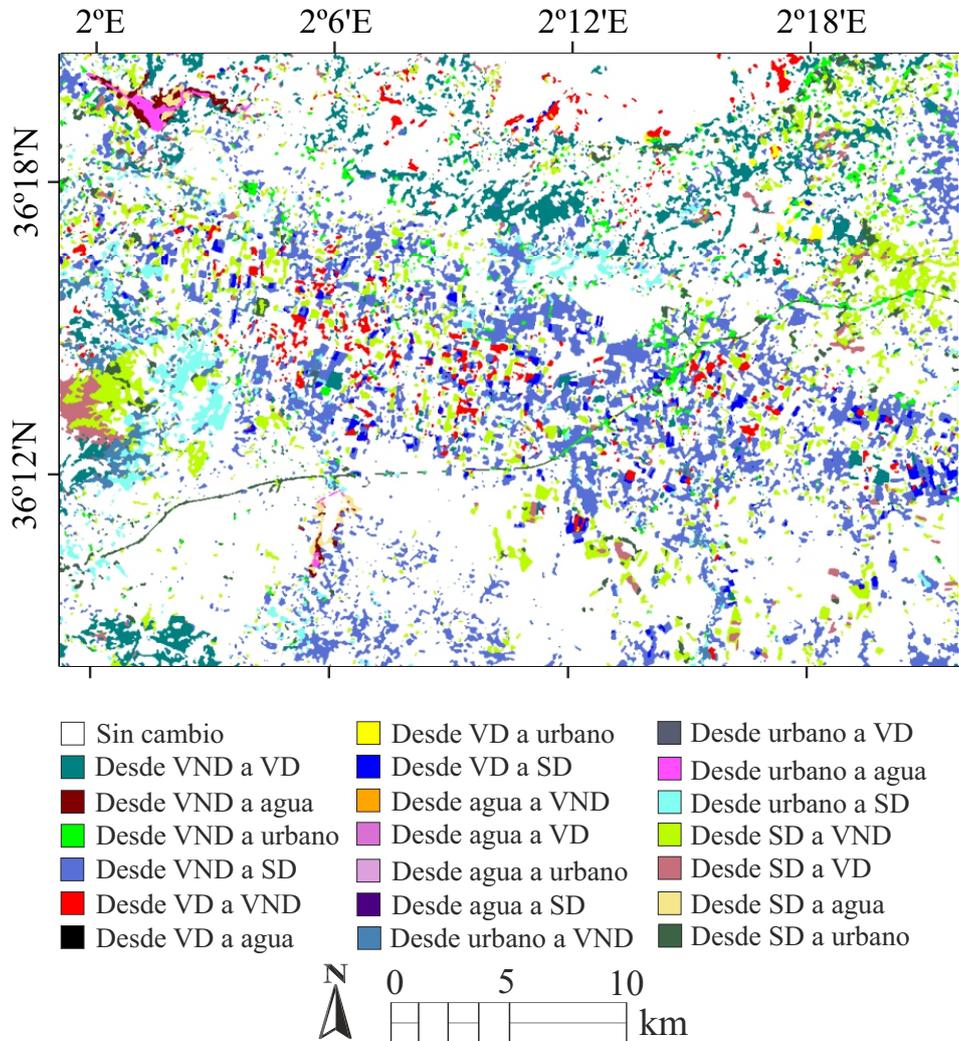


Figura 4.12: Discriminación del cambio en la sub-área de Argelia.

Para evaluar con más precisión los cambios transcurridos entre las escenas se usa la tabla 4.11, que muestra la matriz de transición entre las fechas 2000 y 2010. Además, la tabla 4.12 representa los diferentes índices de cambio de la cubierta terrestre. La ganancia máxima aparece con la clase suelo descubierto, con un porcentaje igual al 38,21%. La pérdida máxima se registra en la clase vegetación no densa, con un porcentaje de 23,42%. Mientras que, la ganancia mínima y la pérdida mínima se registran en la clase agua con un 0,62% y un 0,08% de porcentaje, respectivamente. El cambio desde la clase suelo

Tabla 4.11: Matriz de transición LULC (%) entre 2000 y 2010 en Pekín, China.

2000-2010	VND	VD	Agua	Urbano	SD	Total 2010	Ganancia
VND	1,96	2,43	0,00	0,32	1,70	6,41	4,46
VD	3,04	1,12	0,03	1,01	1,26	6,47	5,35
Agua	0,28	0,04	0,27	0,09	0,22	0,89	0,62
Urbano	5,09	2,31	0,01	18,43	5,60	31,44	13,00
SD	15,01	7,35	0,04	15,82	16,58	54,79	38,21
Total 2000	25,38	13,24	0,35	35,67	25,36	100	61,65
Pérdida	23,42	12,12	0,08	17,24	8,78	61,65	

Tabla 4.12: Los índices de cambio LULC entre 2000 y 2010 (%) en Pekín, China.

Clases	Total 2000	Total 2010	Ganancia	Pérdida	Persistencia	Cambio total	Swap	Cambio Neto
VND	25,38	6,41	4,46	23,42	1,96	27,88	8,92	18,96
VD	13,24	6,47	5,35	12,12	1,12	17,48	10,70	6,77
Agua	0,35	0,89	0,62	0,08	0,27	0,70	0,15	0,55
Urbano	35,67	31,44	13,00	17,24	18,43	30,25	26,01	4,24
SD	25,36	54,79	38,21	8,78	16,58	46,99	17,57	29,42
Total	100	100	61,65	61,65	38,35	61,65	63,35	59,95

descubierto a suelo urbano obtiene un 5,60 %. La clase urbana se gana con un 13,00 % y se pierde a la vez con un 17,24 %. Esto es debido al cambio del uso de la tierra (extensión en el aeropuerto y cambio de zonas urbanas a polígonos industriales). Los valores máximos de persistencia se presentan, con valores de 18,43 % y 16,58 %, para las clases suelo urbano y suelo descubierto, respectivamente. El cambio total en la escena para la clase del suelo descubierto es del 46,99 %, mientras que el máximo del índice swap es del 26,01 % para la clase urbana. El máximo cambio neto aparece en la clase del suelo descubierto con un valor de 29,42 %. Esta clase es la más superficie ocupa en la escena del año 2010. Se demuestra así que este tipo de tablas refleja bien la dinámica de la zona y es útil para los usuarios finales, que quieren comprender el cambio en uso de suelo a nivel regional o global.

Para evaluar los cambios en Argelia, el mismo análisis se aplica en la escena escogida de Argelia en las fechas 2002 y 2010, a través de la matriz de transición, representada en la tabla 4.13, y los índices de cambio, representados en la tabla 4.14. La ganancia máxima se presenta en la clase suelo descubierto, con un porcentaje del 13,96 %, y las pérdidas máximas se registran en la clase vegetación no densa, con porcentaje del 17,95 %. Mientras que, la ganancia mínima se registra en la clase de agua, con un 0,62 %, y la pérdida mínima se observa, con un 2,91 %, en la clase de vegetación densa. El cambio desde la

Tabla 4.13: Matriz de transición LULC (%) entre 2002 y 2010 en Ain Defla, Argelia.

2002-2010	VND	VD	Agua	Urbano	SD	Total 2010	Ganancia
VND	18,06	1,77	0,00	1,57	5,97	27,36	9,30
VD	4,84	10,10	0,00	0,10	1,15	16,19	6,09
Agua	0,21	0,01	0,12	0,19	0,21	0,74	0,62
Urbano	1,86	0,16	0,00	3,21	1,68	6,91	3,70
SD	11,03	0,98	0,00	1,95	34,84	48,80	13,96
Total 2002	36,00	13,01	0,12	7,01	43,86	100	33,67
Pérdida	17,95	2,91	0,00	3,80	9,01	33,67	

Tabla 4.14: Los índices de cambio LULC entre 2002 y 2010 (%) en Ain Defla, Argelia.

Clases	Total 2002	Total 2010	Ganancia	Pérdida	Persistencia	Cambio total	Swap	Cambio Neto
VND	36,00	27,36	9,30	17,95	18,06	27,25	18,60	8,64
VD	13,01	16,19	6,09	2,91	10,10	9,00	5,82	3,18
Agua	0,12	0,74	0,62	0,00	0,12	0,62	0,00	0,62
Urbano	7,01	6,91	3,70	3,80	3,21	7,50	7,40	0,10
SD	43,86	48,80	13,96	9,01	34,84	22,97	18,03	4,94
Total	100	100	33,67	33,67	66,32	33,67	49,86	17,49

clase suelo descubierto y desde vegetación no densa a la clase agua representa un cambio de 0,21 % en ambos casos. También, el cambio desde vegetación no densa a vegetación densa registra un pequeño porcentaje del 4,84 %, y de la vegetación no densa a suelo descubierto cambia el 11,03 %. La clase vegetación no densa gana un 9,30 % y pierde un 17,95 %, mientras que la clase agua gana un 0,62 % y no sufre ninguna pérdida. Esta última ganancia en la clase agua se debe a la construcción de un embalse, que se puede apreciar claramente en la escena 2010 de manera visual. El cambio de la clase vegetación no densa se debe principalmente a los incendios forestales que afectan a esta zona y a la plantación y crecimiento de vegetación en otras áreas. La persistencia máxima, con valores del 34,84 % y del 18,06 %, aparece para las clases suelo descubierto y vegetación no densa, respectivamente. El cambio total de la escena para la clase vegetación no densa es del 27,25 %, mientras que el máximo swap se registra en la misma clase con un 18,60 % y en la clase de suelo descubierto con el porcentaje del 18,03 %. El máximo cambio neto tiene un valor del 8,64 % en la clase vegetación no densa. Este gran cambio es debido a la dinámica de esta clase causada por los incendios forestales. El suelo descubierto es la clase dominante en la escena durante los años de estudio.

Las tablas 4.15 y 4.16 presentan los índices de relación g_p , l_p y n_p con el uso del DFPS para la selección del umbral óptimo en la zona de China y Argelia, respectivamente.

En la tabla 4.15 de China, el índice relación ganancia a persistencia g_p presenta un valor mayor que 1 en las clases vegetación no densa, vegetación densa, agua y suelo descubierto, por lo que resulta que estas clases indican más ganancia que pérdida en el periodo de estudio. Esto es debido al cambio de uso de la tierra, el crecimiento de árboles y la destrucción de zonas urbanas para su rehabilitación. En la columna del índice relación pérdida a persistencia l_p , las clases vegetación no densa y vegetación densa indican un valor superior a 1, por lo que existe una mayor tendencia de que estas clases se conviertan en otras que persistan con el tiempo. La columna n_p indica el índice relación cambio neto a persistencia, y representa la probabilidad de cambio general en cada clase durante el período de estudio.

Tabla 4.15: Los índices g_p , l_p y n_p obtenidos en China.

Clases	g_p	l_p	n_p
VND	2,28	11,97	9,69
VD	4,79	10,85	6,06
Agua	2,32	0,28	2,03
Urbano	0,71	0,94	0,23
SD	2,30	0,53	1,77

La tabla 4.16 presenta los índices de relación en la zona de Argelia. Así, g_p presenta un valor mayor que 1 para la clase agua y clase urbana. Por lo tanto, estas clases ganan más que pierden en el período de estudio. Esto se debe a la construcción de nuevas casas y embalses. Y en la columna de n_p , el índice de relación cambio neto a persistencia presenta la probabilidad de cambio general en cada clase durante el período de estudio.

Tabla 4.16: Los índices g_p , l_p y n_p obtenidos en Argelia.

Clases	g_p	l_p	n_p
VND	0,52	0,99	0,48
VD	0,60	0,29	0,31
Agua	5,16	0,00	5,16
Urbano	1,15	1,19	0,03
SD	0,40	0,26	0,14

4.6 **Discusión**

Se ha descrito una metodología basada en el análisis de vectores de cambio basada en la probabilidad posterior y se ha aplicado en dos escenarios diferentes para comparar su desempeño en escenarios con dinámicas de cambio muy diferentes. El rendimiento del algoritmo propuesto se ha evaluado con datos de validación obtenidos por inspección visual. La evaluación de precisión proporciona un coeficiente kappa superior a 0,8 para ambas áreas de estudio. Los resultados sugieren que el SCVAPS es una metodología que ofrece resultados excelentes y tiene un gran potencial para detección de cambio en teledetección. La selección del umbral óptimo con el método DFPS ha proporcionado resultados muy satisfactorios, a pesar de la complejidad que entraña la selección de las muestras de entrenamiento.

En general, es difícil recopilar información global sobre todos los años de información sobre el uso de la tierra y el cambio de cobertura. La metodología presentada aprovecha las diferencias espacio-temporales entre dos imágenes adquiridas en diferentes fechas. Por esa razón, SCVAPS es un método efectivo en este escenario. La calidad de los datos juega un papel muy importante en el proceso, ya que la adquisición de datos debe hacerse en diferentes años eligiendo la misma temporada. Además, el registro de imágenes tiene un fuerte impacto en la metodología de detección de cambios porque puede presentar artefactos graves debido a la falta de coincidencia de ubicación de píxeles. Se obtienen excelentes resultados gracias a la buena calidad de las imágenes satelitales, las correctas correcciones radiométrica, geométrica y el registro preciso que brinda la metodología propuesta.

En este capítulo se emplea el método DFPS de búsqueda de umbral que ofrece muy buenos resultados en la detección de cambio con vectores CVA. Por otro lado, algunos otros aspectos como la selección de las ventanas dobles de entrenamiento es un aspecto muy crítico en este proceso de determinación de umbral, que además depende de la experiencia del analista. Las ventanas dobles y su clasificación correcta juegan un papel importante en el proceso general de detección de cambio, ya que su selección respetando los requisitos es difícil de lograr. Los resultados de la discriminación han sido excelentes, ya que proporcionan buenos resultados en las dos zonas de estudio, que son muy diferentes entre sí. De esta manera, la metodología se ajusta bien a zonas predominantemente urbanas muy dinámicas y a otras predominantemente naturales con poco cambio. Además, los resultados obtenidos en China y Argelia dibujan bien el cambio esperado de forma acorde con las circunstancias de clima y uso humano.

Detección de desertificación mediante clasificación por objetos e integración de datos radar

En este capítulo se aplican las herramientas estudiadas de detección de cambio al problema de la desertificación en una zona críticamente amenazada en Biskra (Argelia). Posteriormente se desarrolla una metodología basada en clasificación por objetos y detección de cambio con el método PCC empleando primero datos ópticos, para luego añadir datos radar. Finalmente se comparan los resultados obtenidos.

5.1 Introducción

La desertificación por causas naturales es un fenómeno cíclico que ha estado sucediendo durante siglos [271]. Este tema es de gran interés en nuestros días, como lo demuestran varios estudios especialmente en China [46, 84] y África [271–275]. Sin embargo, la desertificación se ha visto agravada en el área del Sahel [234] debido a factores humanos y climáticos, y el desierto del Sahara a veces se aprecia como una amenaza creciente para la población. Por ello, es importante hacer un esfuerzo para establecer una base científica en este tema, tal y como se explica en [43], para la conservación sostenible de los recursos.

La idea de la desertificación amenazando el norte de Argelia se ha tenido en cuenta por parte de las autoridades argelinas en el Ministerio de Agricultura y Desarrollo Rural (MADR) a través de proyectos nacionales de investigación, que también cuentan con el apoyo de otros países. Así, el gobierno argelino combate este grave problema desde

1962 mediante varios programas. La primera iniciativa se basó en plantar barreras de vegetación en los alrededores de la estepa para evitar el avance del desierto [274]. Este proyecto continuó durante la década de 1970 con un programa masivo de reforestación llamado *Green Dam* [43]. El objetivo de esta gran barrera de vegetación, ubicada en el extremo norte del Sahara con 20 km de ancho, era detener la progresión de las dunas de arena [43]. Pero este objetivo no se cumplió y hoy solo quedan rastros de esa barrera formada por unos pocos pinos alepo.

En 1970 se lanzó otro proyecto llamado Revolución Agraria. Su principal objetivo fue regular el uso de la estepa a través de la ganadería [274]. Este programa tampoco tuvo éxito debido a los numerosos conflictos de interés involucrados.

Aún así, la desertificación seguía avanzando a pesar de los intentos realizados en anteriores programas. Debido a ello, en 1983 se creó una institución especial bajo el nombre *Haut Commissariat au Développement de la Steppe (HCDS)*, cuyos objetivos consistían en la conservación del medio ambiente y el desarrollo de estrategias para luchar contra la desertificación, teniendo en cuenta los aspectos naturales y socioeconómicos. Esta institución se dedicó principalmente a la rehabilitación de caminos degradados y a la creación de áreas con pozos de agua. Así, este programa consiguió conservar 3,3 millones de hectáreas de un área potencial de 30 millones de hectáreas. Sin embargo, esta institución no ha logrado desarrollar una estrategia integral y coherente para el desarrollo sostenible de las zonas de estepa [205, 274].

El último intento de lucha contra la desertificación se desarrolló en la década de los años 2000 bajo el programa *Programme National de Développement Agricole (PNDA)* para la explotación agrícola en tierras marginales de estepa.

Se puede concluir que se ha trabajado mucho en este tema, pero que su complejidad hace que su comprensión científica sea aún un verdadero desafío. Los estudios más detallados que tengan en cuenta las características dependientes de la ubicación geográfica, como la metodología presentada en este capítulo, podrían generar resultados muy valiosos para los agentes gubernamentales.

Un análisis sistemático mediante teledetección en el espectro óptico, con el mismo ángulo de incidencia y sensores similares durante un periodo de tiempo, permite una evaluación correcta del cambio de la cobertura terrestre. El análisis de la desertificación en Argelia utilizando teledetección se realizó previamente en In-Salah (Adrar, Argelia) en [205]. En ese trabajo, el método de clasificación elegido fue el algoritmo MLC supervisado por píxel y el objetivo principal era caracterizar las dunas móviles de arena.

La ciudad de Biskra (Argelia), que es el objeto de análisis de esta Tesis, está gravemente amenazada por la desertificación debido a sus condiciones climáticas y orográficas.

Esta área ha sido estudiada en [276] bajo un punto de vista diferente con enfoque en la salinización del suelo utilizando la clasificación basada en árboles de decisión. Esta zona también se estudió en el modelado de presas subterráneas en [277]. Además, se presentó un estudio de la desertificación en Biskra usando datos satelitales de alta y media resolución en [278].

Existe una amplia gama de datos satelitales que permiten un análisis sistemático en el espectro óptico usando sensores pasivos, y en el espectro de microondas usando sensores activos como el *Synthetic Aperture Radar (SAR)*. Además, estas imágenes de radar proporcionan información valiosa y complementaria a los datos ópticos. Algunas características de la tierra tales como la rugosidad del suelo y la humedad se caracterizan claramente mejor por longitudes de onda de microondas que en longitudes de onda ópticas. Las imágenes SAR también representan mejor los objetos hechos por el hombre, debido a sus características eléctricas. Sin embargo, las características propias de los datos radar y ópticos requieren un estudio cuidadoso para su integración conjunta en el proceso de detección de cambio. Los autores en [160] presentaron un trabajo sobre la fusión de imágenes aéreas ópticas de alta resolución y datos SAR (banda X) para la detección de viviendas en entorno rural. La normalización óptima para imágenes ópticas y SAR utilizando *Artificial Neural Networks (ANN)* se presentó en [279]. También existen otras aplicaciones de fusión de datos ópticos y SAR: para la monitorización y estudiar el mapeo de la cobertura terrestre en [280] y para estimar las áreas urbanas y los campamentos de refugiados en [209,210]. Existe un gran interés en el diseño de la metodología con la fusión de datos ópticos y SAR adaptados a aplicaciones específicas. Sin embargo, el problema de la desertificación no se ha estudiado previamente utilizando SAR y datos ópticos. Por ello, en esta Tesis se busca la mejor metodología en el marco de desertificación incluyendo fusión de datos ópticos y SAR en la zona de Argelia. La ventaja al añadir los datos SAR es mejorar la precisión de la detección de cambios y poder complementar la información del suelo (sobre todo durante la presencia de nubes en los datos ópticos).

En el presente capítulo, se estudia el fenómeno de desertificación en la ciudad de Biskra (Argelia) desarrollando dos tareas para la detección del movimiento de las dunas de arena en el Sahara:

1. La primera tarea de este capítulo, en la sección 5.4, consiste en llevar a cabo el Objetivo 2 de la Tesis, presentado anteriormente en la sección 1.1. Este objetivo consiste en usar solamente imágenes ópticas para desarrollar una metodología semiautomática, adecuada para supervisar la degradación de la tierra en una región árida, utilizando el mejor método de clasificación supervisada entre la clasificación por píxel y por objetos. También se selecciona el mejor método de detección de cambio teniendo en cuenta sus resultados y su complejidad de entre las técnicas CVAPS

y PCC. Se selecciona la mejor metodología y se aplica en un estudio a largo plazo (25 años) en la ciudad de Biskra (Argelia). Los píxeles inspeccionados visualmente se toman como datos verdaderos para la validación, con el fin de establecer la calidad de la metodología. Finalmente, la información sobre el cambio se relaciona con los principales factores que influyen en la degradación de la tierra. Esta metodología de bajo coste en términos de procesamiento del analista es valiosa por sí sola, ya que puede ayudar a las autoridades locales a minimizar y prevenir los procesos de degradación utilizando datos de Landsat disponibles de forma gratuita y con un extenso archivo histórico. Este estudio también proporciona el punto de partida para la integración posterior de datos radar.

2. La segunda tarea de este capítulo, detallada en la sección 5.5, es el desarrollo del Objetivo 3 de la Tesis presentado en la sección 1.1, que consiste en seleccionar la mejor metodología semiautomática para la clasificación supervisada utilizando imágenes ópticas e imágenes SAR en banda C de frecuencia (C-SAR), con el fin de crear una herramienta de detección de cambios simple que identifique el movimiento de la arena con datos disponibles de forma abierta. Las imágenes de microondas agregan información valiosa adicional a los productos ópticos existentes, ya que modelan especialmente bien la rugosidad del suelo y su contenido de humedad. La ciudad de Biskra ha sido elegida de nuevo para la evaluación de la desertificación por su alto interés para la comunidad científica. Los datos del Landsat-8 y del Sentinel-1A C-SAR obtenidos en 2015 y 2016 han sido cuidadosamente seleccionados en meses similares. Se han elegido varios índices de detección de cambios relevantes para evaluar el cambio. Los píxeles seleccionados visualmente se toman como datos verdaderos para la validación utilizando fuentes de información adicionales, tales como imágenes de alta resolución tomadas en fechas similares. Finalmente, los resultados se analizan completamente teniendo en cuenta otros problemas que también están involucrados en la degradación de la tierra. Esta metodología desarrollada puede ser de especial interés para los gobiernos regionales que deseen supervisar la dinámica de la tierra con respecto a la desertificación incluyendo datos de microondas.

5.2 Área de estudio

El área de estudio es una zona árida en la región del noreste de Argelia, determinada por los límites desde $34^{\circ}42'N$ hasta $34^{\circ}52'N$ en latitud terrestre y desde $5^{\circ}32'E$ hasta $5^{\circ}51'E$ en longitud terrestre, tal y como se muestra en la figura 5.1. Esta zona cubre un área de $552,82 \text{ km}^2$ con un rango de altitud de 87 a 115 m. Esta región árida alrededor de la ciudad de Biskra se conoce como la Puerta del Desierto. Está rodeada por dunas de arena (Gran Erg Occidental) en la dirección sur y las montañas de Aurés en la dirección

norte. La población de Biskra ha crecido significativamente de 95000 habitantes en 1977 a más de 307987 en 2015, lo que representa un aumento de tres veces en un período de 38 años.

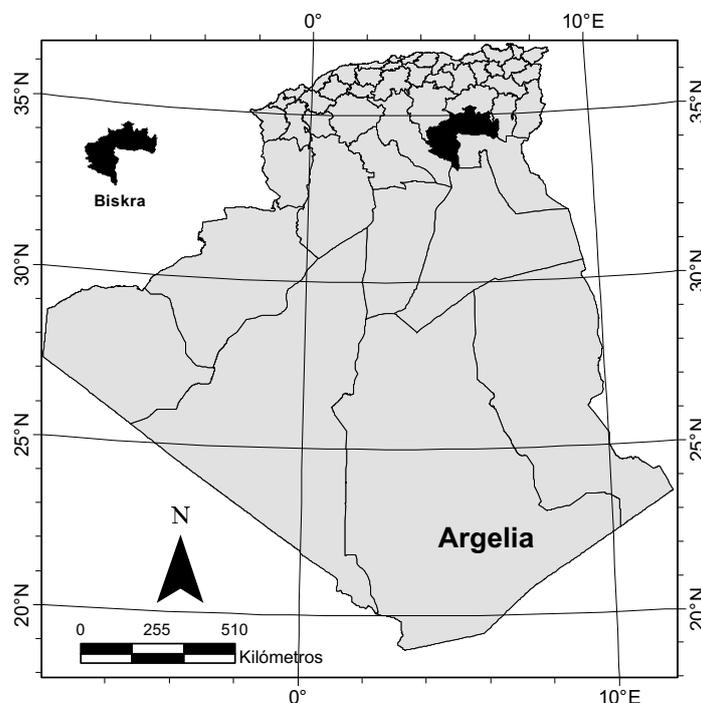


Figura 5.1: Localización geográfica de la zona de estudio.

El estudio LULC se basa en el análisis de imágenes satelitales multitemporales con bajo contenido de nubes, en el caso de imágenes ópticas. Las imágenes utilizadas en este estudio se eligieron del archivo de libre acceso del USGS [269] y del centro de acceso abierto Copernicus de la ESA [281]:

- Se seleccionan diferentes escenas del programa Landsat-5, tomadas en junio con baja presencia de nubes, sus características se muestran en la tabla 5.1. Se usa el mes de junio para este estudio porque pertenece a la estación cálida y seca, que es la temporada más útil para la monitorización de la desertificación. Se elige una zona de 944×649 píxeles para un análisis posterior, con una resolución espacial de 30×30 m. La figura 5.2 muestra una composición de tres bandas (rojo, verde y azul) de las imágenes Landsat y su correspondiente DEM, que es útil para estimar la pendiente del terreno y su influencia en el transporte final de la arena.
- Se seleccionan también dos imágenes de buena calidad del programa Landsat-8 obtenidas en marzo (ver tabla 5.2). Las bandas espectrales que se han utilizado en este

Tabla 5.1: Características de las imágenes de Landsat-5.

Fecha de Adquisición	Sensor ID, N°	Modo del sensor	Path/ Row	Versión LPGS	Tipo de dato	Azimut solar	Elevación solar
04-06-1986	TM, 5	SAM	194/036	12.5.0	L1T	107,09	61,18
13-06-1995	TM, 5	SAM	194/036	12.6.1	L1T	101,37	57,74
14-06-2007	TM, 5	Bumper	194/036	12.5.0	L1T	113,70	67,11
03-06-2009	TM, 5	Bumper	194/036	12.5.0	L1T	114,27	65,89
09-06-2011	TM, 5	Bumper	194/036	12.5.0	L1T	113,19	66,25

Tabla 5.2: Características de las imágenes de Landsat-8.

Fecha de Adquisición	Sensor ID, N°	Modo del sensor	Path/ Row	Versión LPGS	Tipo de dato	Azimut solar	Elevación solar
16-03-2015	OLI, 8 TIRS	TIRS	194/036	2.6.0	L1T	143,75	47,58
02-03-2016	OLI, 8 TIRS	TIRS	194/036	2.6.2	L1T	146,38	42,52

estudio son las bandas Azul (banda 2), Verde (banda 3), Roja (banda 4) e infrarrojo cercano (banda 5). Otras dos escenas con procesamiento de nivel 1 tomadas por el satélite Sentinel-1A (C-SAR) se escogen también para este estudio. La tabla 5.3 muestra las características de las imágenes radar. Sentinel-1A transporta un radar de doble polarización y se seleccionan dos canales para su estudio, uno es la combinación copolar de onda incidente polarizada verticalmente y polarización retrodispersada polarizada verticalmente (VV), y la otra imagen contiene el producto polar cruzado que consiste en la recepción de la onda retrodispersada en polarización horizontal cuando incide sobre el suelo una onda con polarización vertical (VH). Se selecciona el mes de marzo porque en ese mes había datos disponibles de ambas misiones en 2015 y 2016 y las imágenes ópticas presentaban un bajo contenido de nubes en ambas escenas. Después de la definición de la proyección y resolución del mapa a partir de las imágenes geo-referenciadas de Landsat-8 y Sentinel-1A, una zona de 945×650 píxeles se selecciona para el estudio en profundidad. Esta área final presenta una resolución de 30×30 m. Se muestran las imágenes Landsat-8 (bandas de color natural) tomadas en 2015, 2016 y sus correspondientes imágenes SAR VV en la figura 5.3.

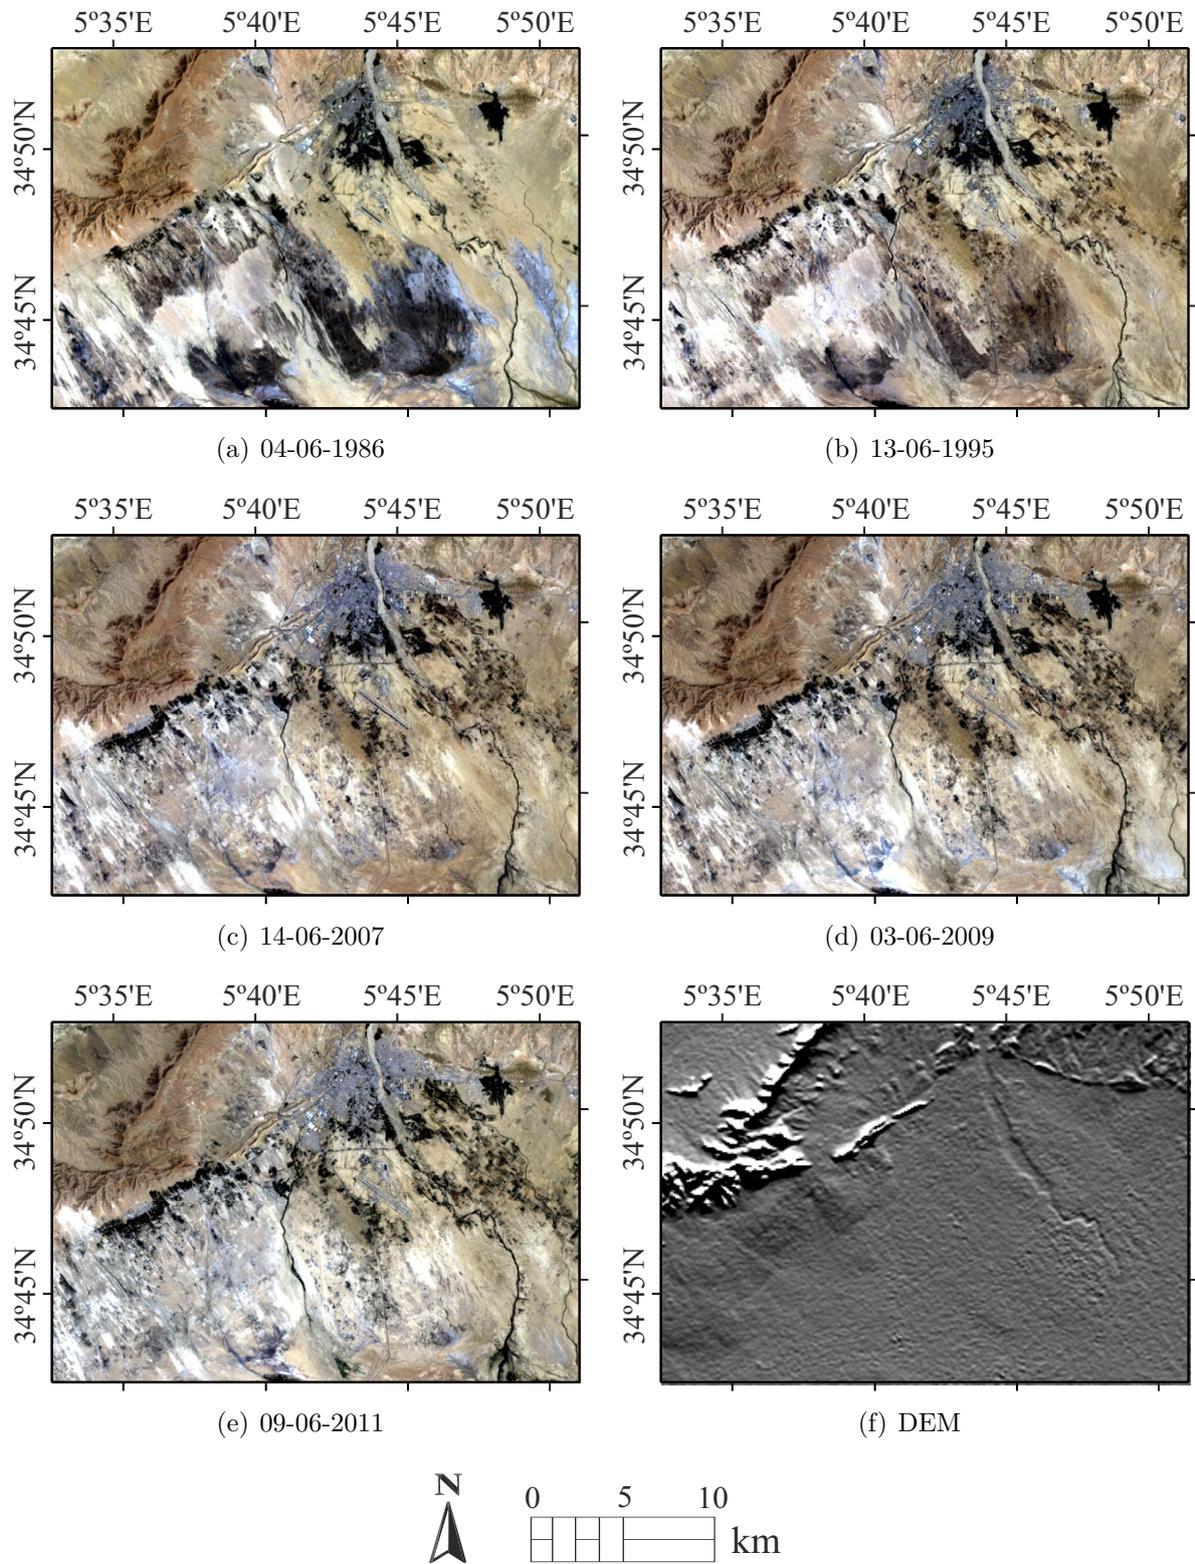


Figura 5.2: Imágenes de Landsat-5 tomadas en los años de estudio y su correspondiente modelo digital de elevación (DEM).

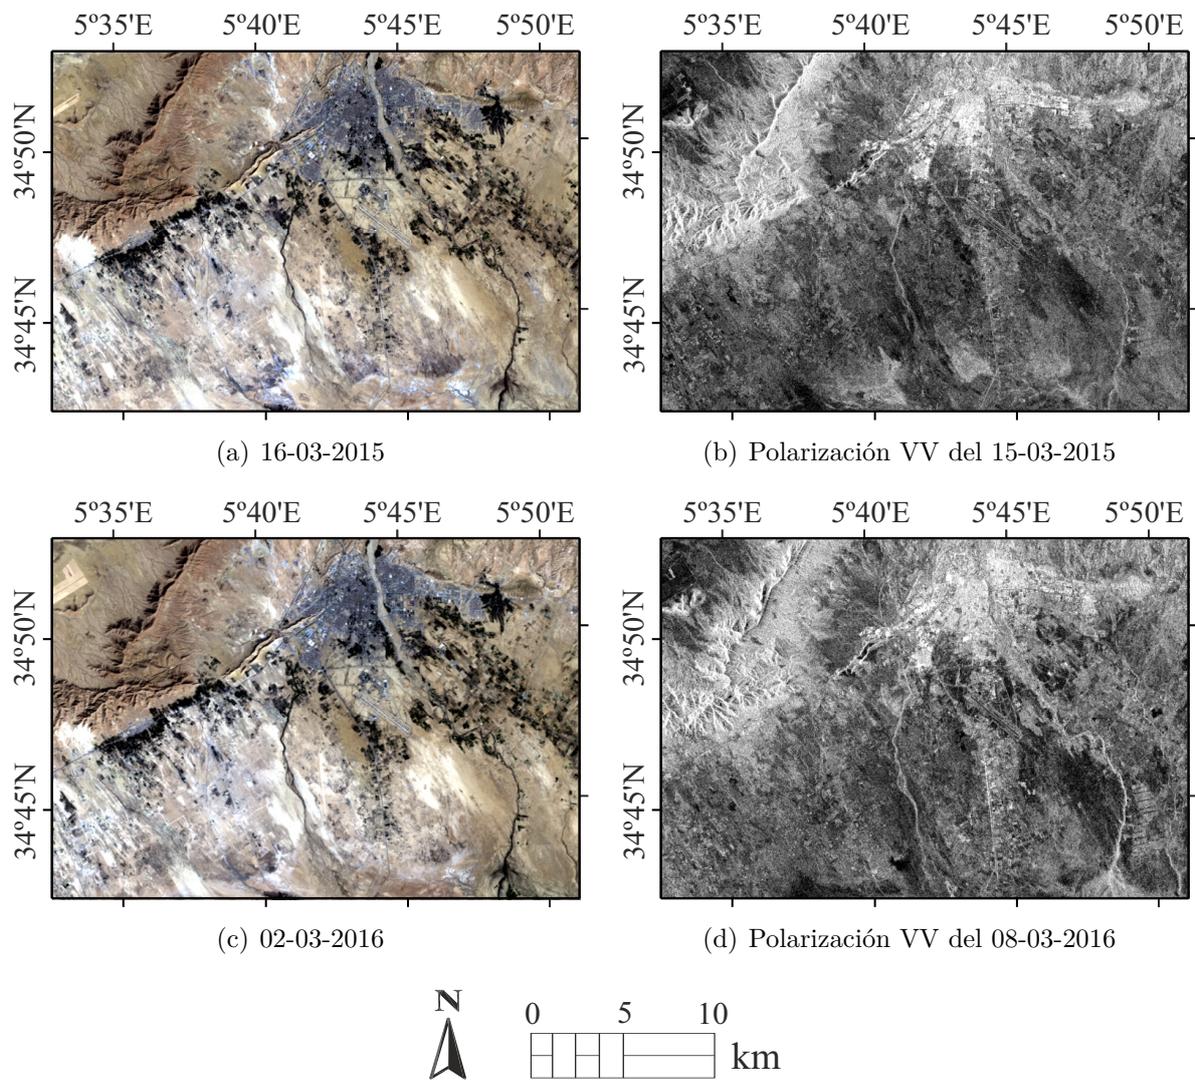


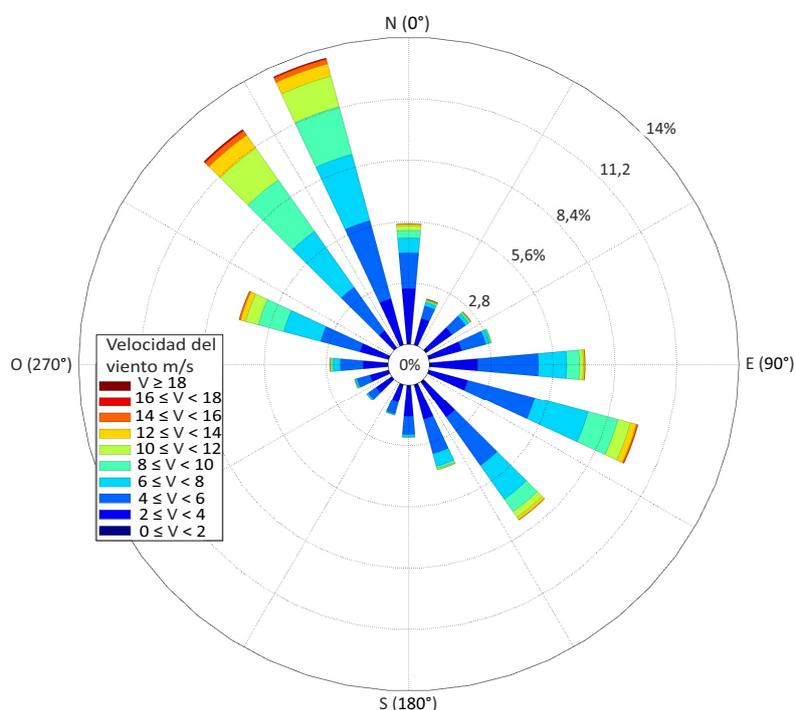
Figura 5.3: Imágenes Landsat-8 tomadas en 2015 en (a) y 2016 en (c), e imágenes Sentinel-1A tomadas en 2015 en (b) y en 2016 en (d).

Tabla 5.3: Características de las imágenes Sentinel-1A.

Fecha de Adquisición	Misión Sentinel	Modo del sensor	Tipo de producto	Numero de órbita	Polarización
15-03-2015	S1A	IW	GRD	5038	DV (doble VV+VH)
08-03-2016	S1A	IW	GRD	10281	DV (doble VV+VH)

Los datos meteorológicos se obtienen del Servicio Federal Ruso de Hidrometeorología y Monitorización Ambiental. La temperatura mínima media en el periodo de estudio está en el rango de 17,39°C a 18,35°C, mientras que la temperatura máxima media va desde 26,13°C a 28,35°C. La temperatura diaria es muy alta de junio a agosto con un valor máximo de 47,2°C. La humedad relativa mínima media está en el rango de 27,75 % a 32,33 %, donde el máximo promedio de la humedad relativa va desde 55,03 % a 62,72 %. El valor total de la precipitación es de alrededor de 135 mm por año.

En esta región, el viento generalmente sopla desde el sureste hacia el noroeste siguiendo la cordillera del Atlas. La velocidad máxima del viento en el período de estudio es de 15 m/s, tal y como se muestra en la figura 5.4. Este viento suele estar más activo en el área árida durante los meses de junio, julio y agosto.

**Figura 5.4:** Amplitud y dirección del viento del 01-02-2005 al 31-12-2016.

Este viento junto con los factores de las altas temperaturas y la baja humedad favorece el desplazamiento de las partículas de arena. El transporte de arena puede ser proporcionado por tres tipos de movimiento: suspensión, saltación y rodadura. Sin embargo, algunos factores pueden afectar la acumulación de arena y la eficacia del viento. El primero es el factor biológico a través de la existencia de vegetación. El segundo es la pendiente del terreno, que depende de la orografía local y el tercero es el factor mecánico que está condicionado por las condiciones del suelo.

5.3 Corrección de imágenes

En el campo de la teledetección óptica, la energía reflejada desde la superficie de la Tierra depende de la pendiente de la superficie y su orientación y los componentes atmosféricos, entre otros factores [282]. Obviamente, también depende de la cobertura de la superficie, que es el objeto de análisis. En este estudio, el objetivo es detectar el movimiento de la arena en un período de tiempo. Para ese propósito, es muy importante asegurar la ubicación conjunta de las imágenes en comparación. Por lo tanto, el procesamiento previo necesario incluye calibración radiométrica, normalización atmosférica, corrección geométrica y registro de imágenes citados en la sección 3.1. En esa parte, la corrección radiométrica se lleva a cabo utilizando el algoritmo de substracción oscura incluido en el software ENVI. La corrección geométrica también se aplica utilizando puntos de control en tierra. Finalmente, el co-registro del área de estudio (figura 5.2) se lleva a cabo siguiendo los procedimientos proporcionados por las herramientas ENVI usando 255 puntos de control. También se calcula el RMSE final, que se encuentra entre 0,001 y 0,16 píxeles. Por otra parte, las imágenes de la figura 5.3 se co-registran usando 106 puntos de control. El RMSE resultante es igual a 0,32 píxeles.

5.4 Detección de desertificación a largo plazo con datos ópticos

Esta primera parte del estudio se basa en diseñar una metodología para detectar la desertificación en un período largo de tiempo de estudio usando imágenes exclusivamente en el rango óptico de frecuencia. Se comparan diferentes tipos de clasificadores por píxeles y por objetos y se elige el mejor método de clasificación. Se comparan también las técnicas de detección de cambio CVAPS, presentada en el capítulo 4, y PCC y se selecciona la mejor metodología teniendo en cuenta sus resultados, su complejidad y el tiempo de procesamiento dedicado a la selección de umbral. La metodología descrita en la figura 5.5 es la que va a servir para detectar el cambio y supervisar los movimientos del arena en Biskra (Argelia). Uno de los pasos clave, será pues escoger el clasificador y el método de detección de cambio más adecuados en nuestro escenario.

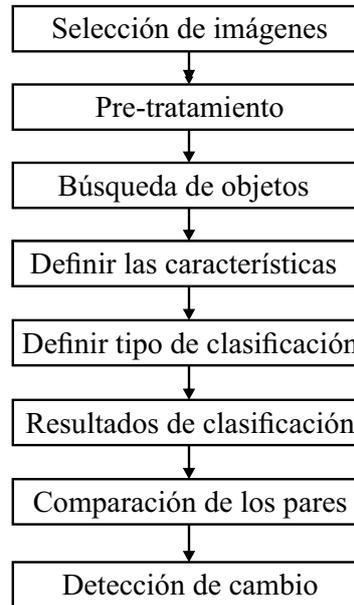


Figura 5.5: Diagrama de flujo de la detección de desertificación.

Tabla 5.4: Clases de cobertura del suelo seleccionadas en el estudio.

Clase	Descripción
Urbano	Edificios, ciudades, pueblos, carreteras
Vegetación	Oasis, parques
Arena	Arena, dunas, erg y regiones moderadamente salinas
Roca	Roca, rosa del desierto, montaña del desierto
Agua	Ríos, lagos, embalses
VND	Campos de cultivo, pastizales

5.4.1 Clasificación de las imágenes ópticas

Primero se realiza un estudio completo de varios métodos de clasificación, incluyendo métodos que trabajan a nivel de píxel y métodos que trabajan con la imagen segmentada o por objetos. Así, se hace un estudio comparativo y se selecciona el mejor clasificador. Se emplea un pequeño número de clases para ese propósito, lo que simplifica el procedimiento. En la detección de desertificación se trabaja la leyenda empleada anteriormente en la Tesis de cinco etiquetas, con la subdivisión de la clase suelo desnudo en arena y roca. Así, seis clases de cobertura terrestre se seleccionan para el estudio, que se muestran en la tabla 5.4. Este es el conjunto mínimo de clases necesarias para evaluar el movimiento de arena en el área de estudio.

Los métodos MLC y SVM de clasificación supervisada que trabajan a nivel de píxel descritos en la sección 3.2.1.1 se seleccionan escogiendo los parámetros de procesado que

optimizan los resultados de precisión. En primer lugar, se aplican en la escena del año 2011 con la selección de una cantidad total de píxeles de entrenamiento del 9,28% del total del área de estudio.

En los métodos de clasificación por objetos, el primer paso es la segmentación. Se emplea para ello la herramienta de extracción de objetos de ENVI, donde un objeto es un grupo de píxeles adyacentes con atributos espectrales similares. El proceso de segmentación seleccionado se basa en un algoritmo de detección de bordes con un nivel de escala de 35% y el proceso de fusión utiliza un enfoque de programación completa de Lambda con un valor de fusión de 80% y un tamaño de kernel de textura de 3 píxeles. Esta selección de parámetros se ha obtenido tras un estudio previo con el fin de obtener un tamaño de objeto óptimo en la zona bajo estudio. Se usa el procedimiento descrito en el diagrama de flujo en la figura 3.2. Para realizar la comparación de clasificadores trabajando sobre objetos se escogen las técnicas de clasificación SVM, KNN, y PCA. En estas clasificaciones se selecciona una cantidad total del 9,02% (del total del área de estudio) para el entrenamiento de la escena de 2011.

El SVM es un método de clasificación supervisado derivado de la teoría estadística del aprendizaje. Se selecciona el tipo de kernel RBF gaussiano para la etapa de clasificación. Este kernel proyecta de manera lineal las muestras en un espacio dimensional más alto, y así consigue resolver el problema también cuando la relación entre las etiquetas de clase y los atributos no es lineal. El kernel RBF requiere elegir dos parámetros: el primero es el parámetro γ , que representa la función radial gaussiana óptima y controla el ancho del núcleo, y el segundo es parámetro de penalización C , que controla la penalización de los errores de clasificación errónea. Se realiza una prueba de validación cruzada auxiliar para obtener los valores óptimos de γ (0,03) y C (100) para manejar problemas de clasificación no separables. El programa *Library for Support Vector Machines (LIBSVM)* desarrollado por [283] e implementado por ENVI se usa en este estudio.

La precisión de los clasificadores MLC y SVM trabajando por píxel y los clasificadores SVM, KNN, PCA trabajando por objetos se comparan usando la escena del año 2011. Se realiza una evaluación de la precisión de la clasificación al comparar los resultados clasificados de todos los métodos analizados, con algunas regiones visualmente seleccionadas de las imágenes, que obviamente son diferentes del conjunto de entrenamiento utilizado en la etapa de clasificación. Las tablas 5.5, 5.6, 5.7, 5.8, 5.9, muestran las matrices de confusión para la clasificación de imagen Landsat de 2011 utilizando los diferentes métodos citados previamente. Para ese proceso de validación de la clasificación, 6668 píxeles clasificados visualmente se seleccionan en diferentes zonas, cubriendo 6,00 km² de datos verdaderos del terreno (1,09% del área total).

Todos los resultados de la clasificación por objetos superan los 80% en termino de

Tabla 5.5: Matriz de confusión para la validación de la clasificación de 2011 con el clasificador MLC por píxel.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1360	9	0	49	0	0	4,09 %
	Vegetación	0	1147	43	0	0	35	6,37 %
	Agua	0	0	23	0	0	0	0,00 %
	Arena	0	0	1	818	5	561	40,94 %
	Roca	0	0	0	553	1078	0	33,91 %
	VND	0	114	0	8	14	850	13,79 %
	Error de omisión	0,00 %	9,69 %	65,67 %	42,72 %	1,73 %	41,22 %	
Precisión global 79,12 %, coeficiente kappa 0,74								

Tabla 5.6: Matriz de confusión para la validación de la clasificación de 2011 con el clasificador SVM por píxel.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1334	16	11	49	4	5	5,99 %
	Vegetación	12	1144	32	0	15	41	8,04 %
	Agua	2	0	23	0	0	0	8,00 %
	Arena	3	0	0	797	19	561	42,25 %
	Roca	1	0	0	557	1025	0	35,25 %
	VND	8	110	1	25	34	839	17,50 %
	Error de omisión	1,91 %	9,92 %	65,67 %	44,19 %	6,56 %	41,98 %	
Precisión global 77,42 %, coeficiente kappa 0,72								

Tabla 5.7: Matriz de confusión para la validación de la clasificación de 2011 con el clasificador SVM por objetos.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1353	15	0	1	0	0	1,17 %
	Vegetación	0	1056	39	0	0	26	5,80 %
	Agua	0	0	18	0	0	0	0,0 %
	Arena	0	3	4	1346	23	8	2,75 %
	Roca	0	23	0	81	1010	0	9,34 %
	VND	7	173	6	0	64	1412	15,04 %
	Error de omisión	0,51 %	16,85 %	73,13 %	5,74 %	7,93 %	2,35 %	
Precisión global 92,91 %, coeficiente kappa 0,91								

Tabla 5.8: Matriz de confusión para la validación de la clasificación de 2011 con el clasificador KNN por objetos.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	961	40	4	61	0	51	13,97 %
	Vegetación	2	1048	40	0	51	25	10,12 %
	Agua	0	0	18	0	0	0	0,0 %
	Arena	0	0	4	1346	11	43	4,13 %
	Roca	381	107	0	21	996	4	34,00 %
	VND	16	75	1	0	39	1323	9,01 %
	Error de omisión	29,34 %	17,48 %	73,13 %	5,74 %	9,21 %	8,51 %	
Precisión global 85,36 %, coeficiente kappa 0,82								

Tabla 5.9: Matriz de confusión para la validación de la clasificación de 2011 con el clasificador PCA por objetos.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	831	65	44	0	66	39	20,48 %
	Vegetación	0	881	0	0	0	20	2,22 %
	Agua	0	0	18	0	0	0	0,0 %
	Arena	10	3	4	1408	13	15	3,10 %
	Roca	21	55	0	0	829	0	8,40 %
	VND	498	266	1	20	189	1372	41,52 %
	Error de omisión	38,90 %	30,63 %	73,13 %	1,40 %	24,43 %	5,12 %	
Precisión global 80,01 %, coeficiente kappa 0,75								

la PG y obtienen un valor de CK a partir de 0,75. En contraposición, los métodos de clasificación por píxeles proporcionan una PG debajo de los 80 % y un CK menor que 0,75. La clasificación MLC por píxel da 79,12 % de PG y 0,74 de CK (ver la tabla 5.5), mientras que la clasificación SVM por píxel da el peor resultado con una PG de 77,42 % y un CK de 0,72 % (ver la tabla 5.6). La tabla 5.7 otorga los mejores resultados a la técnica SVM por objetos con una PG de 92,91 % y un CK de 0,91 %.

Con estos resultados de clasificación, el algoritmo SVM por objetos es la técnica seleccionada para la clasificación, después de considerar diferentes opciones de clasificación por objetos y por píxel, porque proporciona los mejores resultados en términos de precisión general y explota de forma óptima los atributos espectrales, espaciales y de textura. Este método supervisado se basa en algunas muestras de entrenamiento para cada tipo de uso de suelo seleccionado por el operador humano. Se emplea una metodología basada en ejemplos y se elige el número de muestras de entrenamiento de 497 a 1131 píxeles para cada una de las cinco imágenes de Landsat-5 TM.

5.4.2 Métodos de detección de cambio

El análisis de detección de cambio es el procedimiento que identifica el cambio ocurrido en un período de tiempo, junto con su ubicación y su tipo. Para estudiar y evaluar la detección de cambio de desertificación se emplea el diagrama de flujo presentado en la figura 5.5. En esta fase de detección de cambio, se comparan los métodos CVAPS y el PCC y se selecciona el mejor método para una detección de cambio multitemporal.

El método CVAPS es una versión del CVA que analiza los vectores de probabilidad a posteriori. Proporciona sus propias características y su guía para diseñar el cambio y discriminarlo. Pero entraña cierta complejidad en la selección de las ventanas dobles de entrenamiento para buscar el óptimo umbral con el método DFPS, tal y como se comenta en el capítulo previo.

El método PCC es un método sencillo y clásico, no necesita el análisis de los vectores de probabilidad a posteriori, ni la selección del umbral pero requiere una clasificación de buena calidad para una detección de cambio exitosa. De cualquier modo, el método CVAPS también necesita la clasificación como una etapa intermedia de su proceso.

5.4.2.1 Selección de umbral

El método CVAPS requiere escoger un umbral y se escoge la técnica clásica DFPS descrita en 4.4.1 para ello. Esta etapa supervisada constituye el proceso más costoso en términos de tiempo de operador humano. En este proceso, se seleccionan cuatro ventanas dobles por parte del analista, que incluyen 3241 píxeles cambiados y 3197 píxeles no cambiados, y cumplen los requisitos descritos en el punto uno de la sección 4.4.1. El proceso de búsqueda comienza en el rango $[0, 6,520]$ con el paso 0,652 en la primera iteración. Como resultado, el umbral obtenido tiene un valor de 3,151 con un porcentaje de éxito del 71,156%. La tabla 5.10 presenta el progreso del proceso de búsqueda en el rango anterior con los pasos 0,6520, 0,2173, 0,0724 y 0,0362. Este proceso necesita 29 evaluaciones del parámetro de calidad en todas las ventanas dobles para alcanzar el umbral óptimo.

Tabla 5.10: Resultados de la selección de umbral con el método *Double-Window Flexible Pace Search (DFPS)* en el período de estudio de 1986 a 2011.

Rango = [6,520,0] Paso = 0,6520		Rango = [3,912,2,608] Paso = 0,2173		Rango = [3,260,2,825] Paso = 0,0724		Rango = [3,188,3,043] Paso = 0,0362	
Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito	Umbral	Porcentaje de éxito
6,520	32,154	3,912	65,742	3,260	70,362	3,188	70,821
5,868	37,956	3,695	66,762	3,188	70,821	3,151	71,156
5,216	41,669	3,477	68,015	3,115	71,141	3,115	71,141
4,564	53,631	3,260	70,362	3,043	71,025	3,079	71,096
3,912	65,742	3,043	71,025	2,970	70,008	3,043	71,025
3,260	70,362	2,825	67,402	2,898	69,125		
2,608	66,800	2,608	66,800	2,825	67,402		
1,956	52,981						
1,304	50,072						
0,652	40,930						

Tabla 5.11: Matriz de confusión del cambio con el método CVAPS en el período de estudio de 1986 a 2011.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	13485	951	14436	6,59 %
	Píxeles cambiados	986	11856	12842	7,68 %
	Total	14471	12807	27278	
	Error de omisión	6,81 %	7,43 %		
Precisión global 92,89 %, coeficiente kappa 0,85					

Una vez se ha estimado el umbral, se puede proceder a la comparación de los dos métodos de detección de cambios con vectores CVA y la comparación post-clasificación.

5.4.2.2 Comparación de técnicas de detección de cambio

Para seleccionar el método de detección de cambio, se comparan los resultados producidos por el método CVAPS y por la técnica PCC. Las tablas 5.11 y 5.12 representan las matrices de confusión para el cambio final entre 1986 y 2011 del método CVAPS y PCC. Se obtiene la precisión global y el coeficiente kappa para el resultado final cambio/no-cambio. El conjunto de validación es diferente del conjunto de datos de entrenamiento utilizado para la clasificación, con el fin de obtener una evaluación de precisión rigurosa. Para tal fin, 24,55 km² (4,45 % del área) de datos del suelo verdadero con 14471 píxeles no-cambiados y 12807 píxeles cambiados se seleccionan mediante inspección visual. Como elemento de comparación, el trabajo que se ha tomado de referencia en la literatura en [101] selecciona 1248 píxeles no-cambiados y 1212 píxeles cambiados para calcular sus resultados finales de precisión en el cambio. En nuestro caso se ha realizado una validación mucho más extensa.

La matriz de confusión cambio/no-cambio que usa el par de imágenes tomadas en 1986 y 2011 con el método CVAPS proporciona un coeficiente kappa de 0,85 y una precisión global igual a 92,89 %, mientras que la matriz de confusión cambio/no-cambio del método PCC muestra excelentes resultados con un coeficiente kappa de 0,90 y una precisión global igual a 95,15 %. En ambos métodos la precisión global supera el 90 % y el coeficiente kappa logra un valor mayor que 0,8, pero la complejidad de ambos es totalmente diferente. El método CVAPS requiere un análisis profundo de los vectores de probabilidad a posteriori, e incluye la selección del umbral con el método DFPS. Por otra

Tabla 5.12: Matriz de confusión del cambio con el método comparación post-clasificación en el período de estudio de 1986 a 2011.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	13932	783	14715	5,32 %
	Píxeles cambiados	539	12024	12563	4,29 %
	Total	14471	12807	27278	
	Error de omisión	3,72 %	6,11 %		
Precisión global 95,15 %, coeficiente kappa 0,90					

parte, el método PCC no requiere el análisis de vectores ni la selección de umbral, pero necesita una clasificación suficientemente exacta para comparar los resultados con garantía de éxito. En el caso de detección de cambio multi-temporal (a largo plazo) es claramente más conveniente usar el método PCC que el CVAPS, para evitar la búsqueda del umbral. Esto es así si se cuenta con una buena clasificación de las imágenes, lo que aplica en nuestro caso. De esta manera se produce una reducción de tiempo de procesamiento, que se puede invertir en una mejor supervisión de la clasificación. Además, el método PCC proporciona mejores resultados de precisión.

5.4.3 Resultados y discusión

Una vez que se valida la etapa de clasificación y detección de cambio, se aplica el mismo método y proceso a las imágenes Landsat tomadas en los años 1986, 1995, 2007 y 2009. Se producen las matrices de confusión para las clasificaciones de 1986, 1995, 2007, 2009 y 2011, y se obtiene una precisión global de 93,95 %, 84,89 %, 86,92 %, 93,12 % y 92,91 %, y valores del coeficiente kappa de 0,88, 0,78, 0,81, 0,89 y 0,91, respectivamente. La tabla 5.13 resume los resultados obtenidos. Los excelentes resultados de precisión global y el coeficiente kappa se calculan de acuerdo con la descripción de la subsección 3.4.1.1.

Los resultados de la clasificación mostrados en la tabla 5.14 muestran la dinámica de los cambios ocurridos en la cobertura de la tierra en el área de estudio durante un período de 25 años.

En la etapa de detección de cambio se usa la herramienta *Thematic Change Workflow* de ENVI. La comparación PCC se utiliza en la siguiente parte del estudio para obtener el tipo de cambio, descrito en [204]. Este proceso identifica las clases de cambio “desde-a” [91] y su grado de éxito depende principalmente de la fiabilidad de la clasificación de la

Tabla 5.13: Resultados de la clasificación por objetos usando el método SVM.

Imagen	PG(%)	CK
04-06-1984	93,95	0,88
13-06-1995	84,89	0,78
14-06-2007	86,92	0,81
03-06-2009	93,12	0,89
09-06-2011	92,91	0,91

Tabla 5.14: Superficie (km²) de las clases en el área de estudio entre 1986 y 2011.

Clase\Año	1986	1995	2007	2009	2011
Urbano	13,53	25,54	38,09	38,62	40,41
Vegetación	61,36	20,70	30,34	30,16	35,52
Agua	4,12	0,45	0,068	0,15	0,05
Arena	262,71	246,88	236,65	275,52	272,42
Roca	119,58	58,95	101,006	90,63	93,19
VND	90,08	198,85	145,23	116,32	109,79

imagen. La evaluación de detección de cambio se aplica mediante pares de imágenes con diferentes fechas de adquisición: 1986-1995, 1995-2007, 2007-2009, 2009-2011 y 1986-2011. A continuación, se comparan los pares de imágenes a través de las matrices de transición descritas en la sección 3.4 para el análisis de las transiciones entre clases. La tabla 5.15 muestra la matriz de transición de la cobertura de la tierra para los pares de imágenes 1986-1995, 1995-2007, 2007-2009, 2009-2011 y 1986-2011. La diagonal de cada matriz da una idea de la persistencia de cada clase y las entradas fuera de la diagonal representan la transición entre clases durante el período estudiado.

Tabla 5.15: Matrices de transición LULC (%): en a) de 1986 a 1995, en b) de 1995 a 2007, en c) de 2007 a 2009.

a) 1986-1995	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 1995	Ganancia
Urbano	1,54	0,25	0,03	0,98	1,44	0,39	4,63	3,09
Vegetación	0,13	2,17	0,44	0,34	0,61	0,07	3,75	1,58
Agua	0,01	0,00	0,00	0,04	0,01	0,01	0,08	0,08
Arena	0,22	0,22	0,05	34,39	4,60	5,29	44,77	10,38
Roca	0,03	0,00	0,00	1,48	9,16	0,01	10,69	1,53
VND	0,53	8,47	0,22	10,41	5,86	10,58	36,07	25,49
Total 1986	2,45	11,12	0,75	47,65	21,69	16,34	100	42,15
Pérdida	0,92	8,96	0,74	13,25	12,52	5,76	42,15	
b) 1995-2007	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 2007	Ganancia
Urbano	3,69	0,28	0,02	1,58	0,18	1,15	6,90	3,21
Vegetación	0,20	2,91	0,02	0,28	0,08	2,02	5,50	2,59
Agua	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,01
Arena	0,21	0,03	0,01	28,04	0,28	14,23	42,80	14,76
Roca	0,32	0,09	0,02	6,28	9,83	1,62	18,15	8,32
VND	0,21	0,44	0,02	8,40	0,32	16,88	26,27	9,39
Total 1995	4,64	3,75	0,08	44,57	10,69	35,90	100	38,28
Pérdida	0,94	0,84	0,08	16,53	0,86	19,02	38,28	
c) 2007-2009	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 2009	Ganancia
Urbano	5,04	0,21	0,01	0,67	0,28	0,80	7,00	1,96
Vegetación	0,22	4,07	0,00	0,12	0,37	0,68	5,47	1,39
Agua	0,00	0,01	0,00	0,00	0,00	0,02	0,03	0,03
Arena	0,62	0,02	0,00	34,87	6,09	8,28	49,88	15,01
Roca	0,17	0,12	0,00	2,47	10,35	3,27	16,39	6,04
VND	0,85	1,07	0,00	4,71	1,13	13,26	21,02	7,76
Total 2007	6,90	5,50	0,01	42,84	18,21	26,31	100	32,19
Pérdida	1,86	1,43	0,01	7,97	7,87	13,05	32,19	

Tabla 5.15: – (Matrices de transición (%): en d) de 2009 a 2011, en e) de 1986 a 2011.)

d) 2009-2011	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 2011	Ganancia
Urbano	5,23	0,31	0,00	0,54	0,09	1,15	7,33	2,10
Vegetación	0,10	4,29	0,02	0,06	0,21	1,73	6,42	2,13
Agua	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,01
Arena	0,39	0,19	0,00	41,34	1,70	5,62	49,24	7,90
Roca	0,28	0,06	0,00	3,67	11,86	0,99	16,87	5,01
VND	0,99	0,61	0,00	4,25	2,48	11,54	19,87	8,33
Total 2009	7,00	5,47	0,03	49,87	16,34	21,03	100	25,47
Pérdida	1,77	1,17	0,03	8,52	4,48	9,49	25,47	
e) 1986-2011	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 2011	Ganancia
Urbano	1,77	0,78	0,03	2,36	1,74	0,65	7,33	5,56
Vegetación	0,18	1,79	0,54	2,05	1,46	0,42	6,44	4,65
Agua	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01
Arena	0,08	6,10	0,02	26,78	4,28	12,08	49,35	22,57
Roca	0,09	0,01	0,01	5,84	10,79	0,13	16,87	6,08
VND	0,33	2,44	0,15	10,56	3,38	3,03	19,90	16,87
Total 1986	2,45	11,13	0,75	47,60	21,66	16,31	100	55,74
Pérdida	0,68	9,33	0,75	20,82	10,87	13,29	55,74	

En el estudio de 1986 a 1995, se encuentra que la arena es el componente principal en el área de estudio en 1995, con un 44,77%. La vegetación no densa es la clase que contribuye de manera mayoritaria, con el 5,29%, a las nuevas áreas de la clase arena. Esta transformación de vegetación no densa a arena está causada por el viento y las variaciones del medio ambiente. Por lo tanto, se puede deducir que el viento es el principal factor en el transporte de partículas de arena a las zonas áridas en el noroeste de Biskra. Durante el período de 1995 a 2007, de 2007 a 2009 y de 2009 a 2011, el cambio principal se vuelve a encontrar desde la vegetación no densa a la arena, lo que ocasiona la degradación de áreas críticas, que incluyen campos de cultivo. En el período total de 1986 a 2011, la clase de arena obtiene la ganancia más alta con 22,57% en 2011 y también presenta la mayor pérdida con 20,82% del cambio total de la cubierta terrestre en 1986. Eso significa que esta clase es la más dinámica en el mapa de cambio. La matriz de transición correspondiente muestra que el intercambio más importante de 1986 a 2011 es de nuevo la conversión de vegetación no densa a arena, con un porcentaje de 12,08% de la transición. El cambio de la vegetación a la arena tiene una contribución del 6,10%, y el cambio de roca a arena contribuye con un 4,28% de la transición total. También hay un porcentaje mínimo de área urbana convertida en arena con una proporción igual a 0,08% de la transición. La sequedad durante el verano, con la presencia de fuertes vientos, permite la migración de los granos de arena de las dunas hacia el noroeste de la zona de estudio. La acumulación de esas partículas de arena causa la creación de dunas, que conduce a una mayor degradación de la tierra.

Para la evaluación del cambio en la cobertura terrestre se calculan diferentes índices: ganancia, pérdida, persistencia, cambio total, cambio y valor absoluto del cambio neto, relación de pérdida a persistencia l_p , relación de ganancia a persistencia g_p y relación cambio neto a persistencia n_p , descritos en la sección 3.4. La tabla 5.16 representa los valores de los índices de cambio para cada clase del LULC durante el período comprendido entre 1986 y 2011. Las categorías de uso de la tierra que experimentan las mayores ganancias son: arena con un 22,57%, vegetación no densa con un 16,87%, roca con un 6,08%, y urbano con el 5,56%. Las pérdidas más altas en el mismo período se observan para arena con 20,82% y vegetación no densa con 13,29%. Estos datos implican un movimiento importante entre clases involucrando casi siempre a la clase arena. Esto se demuestra con el valor de swap. Las clases de arena y vegetación no densa muestran altos niveles de swap con 41,63% y 26,57%, en comparación con otras clases. Eso valida el hecho de que estas clases están críticamente involucradas en el movimiento de los granos de arena procedentes de las dunas del suroeste de Biskra, que son la principal fuente de desertificación para las áreas de cultivo del norte de Biskra. El agua no presenta cambios significativos con un swap de 0,02% y un cambio neto de 0,74% porque tiene baja presencia en el sur de Argelia.

Tabla 5.16: Índices de cambio LULC entre 1986 y 2011 (%).

Clases	Total 1986	Total 2011	Ganancia	Pérdida	Persistencia	Cambio total	Swap	Cambio Neto
Urbano	2,45	7,33	5,56	0,68	1,77	6,24	1,37	4,88
Vegetación	11,13	6,44	4,65	9,33	1,79	13,98	9,30	4,68
Agua	0,75	0,01	0,01	0,75	0,00	0,76	0,02	0,74
Arena	47,60	49,35	22,57	20,82	26,78	43,38	41,63	1,75
Roca	21,66	16,87	6,08	10,87	10,79	16,95	12,16	4,79
VND	16,31	19,90	16,87	13,29	3,03	30,16	26,57	3,59
Total	100	100	55,74	55,74	44,16	55,74	91,05	20,43

Se ha comprobado que durante el período de tiempo estudiado se produce un cambio significativo en Biskra. Las transiciones más importantes aparecen para las clases de arena, vegetación no densa y la clase urbana, ésta última relacionada con el aumento de la población. La cantidad de superficie inalterada entre 1986 y 2011 es igual al 44,16 %. Por lo tanto, la región estudiada indica un significativo cambio total de 55,74 % del área.

La relación de pérdida a persistencia l_p permite evaluar el riesgo de cambio de la cobertura terrestre. Cuando el valor de l_p es mayor que 1, la cobertura terrestre está más expuesta a cambios a otras clases a que persistan con el tiempo. Las clases urbano, agua y arena presentan un valor de l_p inferior a 1 que se muestra en la tabla 5.17, y que confirma la baja tendencia de transición a otras clases. La clase vegetación y vegetación no densa indican valores altos de l_p iguales a 5,20 y 4,39 respectivamente, y este hecho sugiere que estas clases son propensas a disminuir su representación en el futuro. Por lo tanto, la relación l_p es una herramienta muy valiosa para la monitorización de la degradación de vegetación, que es uno de los elementos más críticos en la desertificación.

Tabla 5.17: Relación ganancia a persistencia g_p , relación pérdida a persistencia l_p y relación cambio neto a persistencia n_p en el período de 1986 a 2011.

Clases	g_p	l_p	n_p
Urbano	3,14	0,39	2,76
Vegetación	2,59	5,20	2,61
Agua	0,00	0,00	0,00
Arena	0,84	0,78	0,07
Roca	0,56	1,01	0,44
VND	5,57	4,39	1,18

Las relaciones de ganancia a persistencia g_p superiores a 1 indican una mayor posibilidad de que la clase gane área de que persista. Las clases urbano, vegetación y vegetación no densa con valores de g_p iguales a 3,14, 2,59 y 5,57, respectivamente, presentan las pro-

porciones más altas de g_p , mostrando más ganancia que persistencia. El valor de g_p para el agua, la arena y la roca es inferior a 1, lo que implica que sus valores de ganancia son más bajos que sus valores de persistencia correspondientes durante el período estudiado. La relación de coeficiente neto de cambio a persistencia n_p de la clase urbana es igual a 2,76 y esto se explica de nuevo por el crecimiento de la población en Biskra.

La distribución espacial de las transiciones del uso de la tierra para los diferentes pares de imágenes se muestra en la figura 5.6. Muchos píxeles cambian debido al crecimiento urbano, a los años de sequía y al movimiento de arena con el flujo de aire que viene desde el sureste del Sahara. En esta zona, la topografía y el viento juegan un papel importante en la acumulación de arena en las faldas del Atlas. La figura 5.6 muestra la transición entre las clases durante el período total 1986-2011, donde una gran área marrón describe la transición de otras clases a arena. Este hecho confirma una progresión muy rápida de las dunas de arena que puede preceder a un proceso de desertificación en el norte de la zona estudiada y cuyo conocimiento puede ser muy relevante para las instituciones locales y nacionales. Se demuestra que los programas de protección contra la desertificación no están teniendo éxito en su objetivo de limitar el crecimiento del desierto, y que la erosión del suelo ha aumentado en la zona. Debido a ello, las autoridades argelinas deberían establecer herramientas más efectivas de planificación y supervisión para una protección eficiente contra la desertificación en la zona.

Aquí se ha presentado una metodología simple para el estudio del proceso de desertificación en Biskra (Argelia) durante 25 años (de 1986 hasta 2011) usando datos disponibles gratuitamente e información local. Se ha introducido una metodología basada en la detección de cambios posteriores a la clasificación SVM basada en objetos. Se obtienen resultados muy precisos con una baja cantidad de píxeles de entrenamiento, lo que representa un bajo coste en tiempo de operador. El resultado más importante para el usuario es una combinación de mapas de cambio en soporte gráfico y una forma compacta de índices y relaciones de índices que pueden procesarse fácilmente. Una vez que se realice un estudio minucioso de este tipo, se podría diseñar un plan para el establecimiento de una barrera natural con importantes beneficios para la población en el área con mayores probabilidades de éxito. Los estudios de este tipo son muy interesantes para las autoridades locales en regiones donde las actividades económicas y la población se ven amenazadas por factores climáticos y ambientales. Para aumentar la precisión de detección y poder sacar más información de la zona de estudio se van a introducir datos SAR en la cadena de procesado, que no dependen de la aparición de nubes y están siempre disponibles. Así, en la siguiente sección se estudia la desertificación en Biskra con la fusión de datos ópticos y del radar.

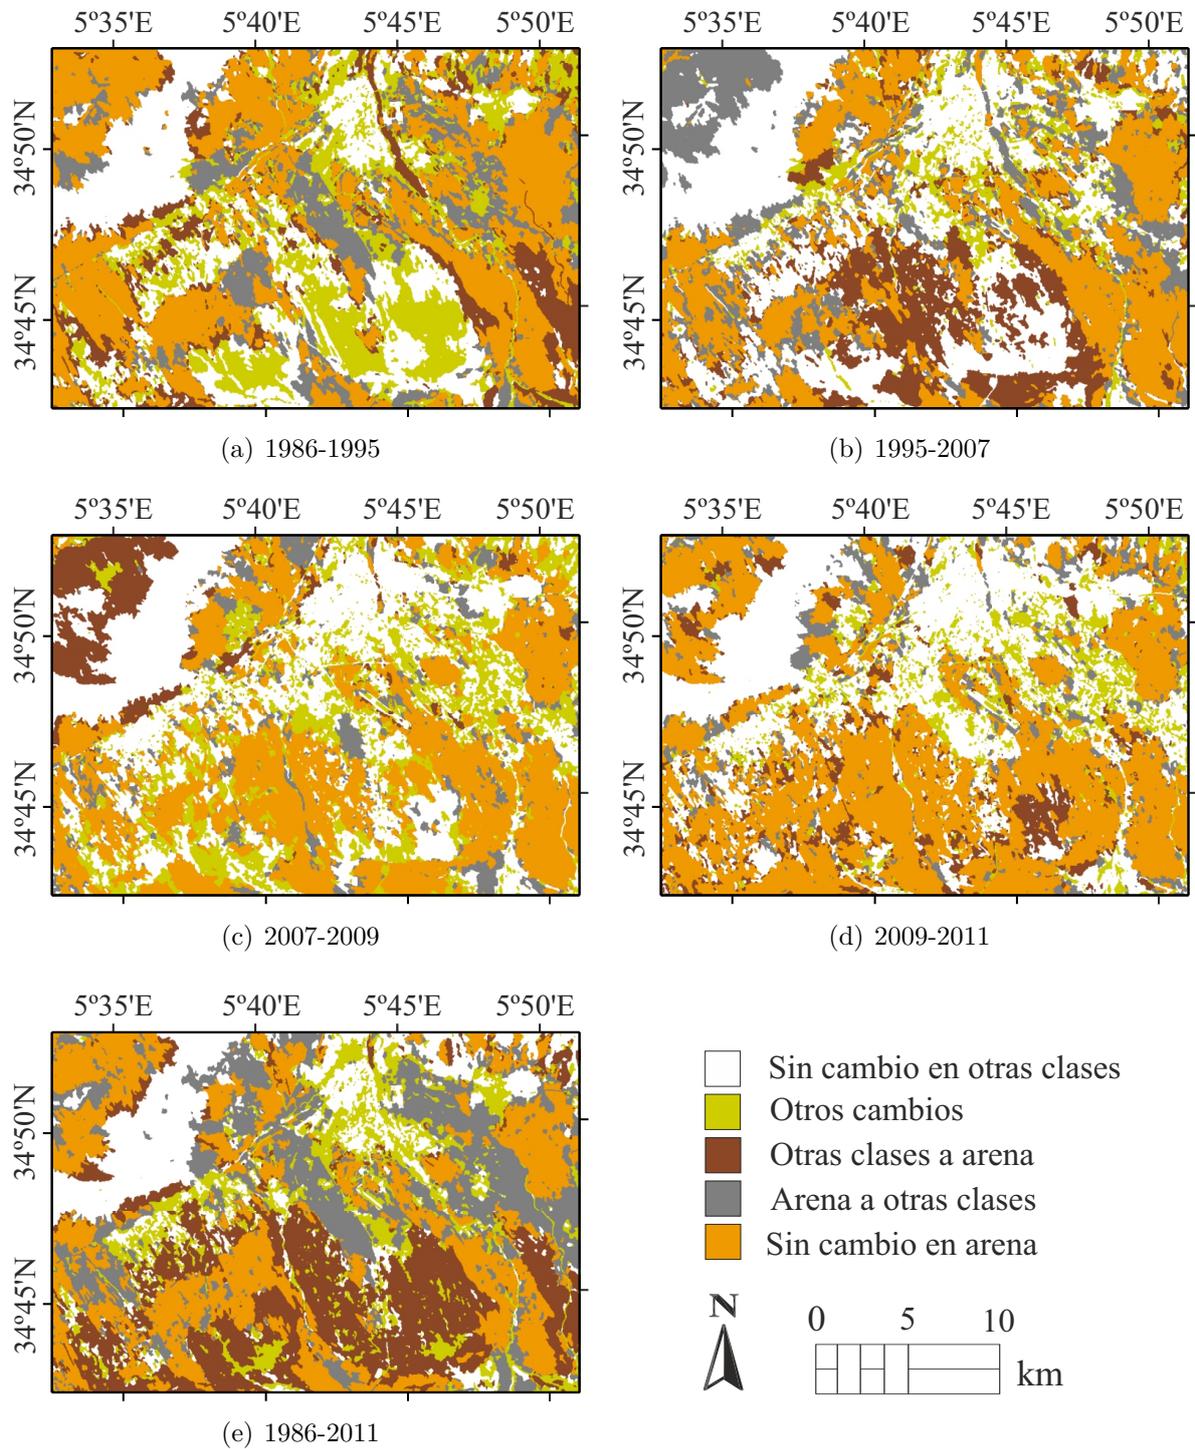


Figura 5.6: Distribución del cambio LULC en los siguientes pares de imágenes: a) utilizando el par 1986-1995, en b) 1995-2007, en c) 2007-2009, en d) 2009-2011 y en e) utilizando el período completo 1986-2011.

5.5 Detección de desertificación a corto plazo con datos ópticos y radar

En esta sección se parte de la metodología diseñada anteriormente y se investiga la mejor manera de integrar datos de imagen de microondas en la cadena de procesado. Se comparan distintas estrategias en el método de clasificación por objetos, que tienen en cuenta las características polarimétricas, el uso de la imagen radar para la segmentación, y la reducción del ruido Speckle en la imagen SAR. Se elige el mejor método comparando la precisión global y el coeficiente kappa de cada uno de ellos. A continuación se usa la herramienta *Thematic Change Workflow* de ENVI para detectar el cambio entre las dos imágenes y se evalúa el movimiento de arena en Biskra (Argelia). Se usan diferentes índices para detectar la discriminación del cambio y supervisar la expansión del arena. Así, se llega a obtener la mejor metodología conjunta de clasificación y fusión de la imagen radar y óptica y se evalúa la mejora de esta metodología con respecto a la que emplea solamente datos ópticos.

5.5.1 Corrección de imágenes radar

Los datos ópticos conservan de forma natural los detalles de la imagen y los datos del radar aportan información valiosa adicional a los productos ópticos, que incluye entre otros la rugosidad del suelo y el contenido de humedad. También son una herramienta muy valiosa para detectar objetos hechos por el hombre con respecto a los terrenos naturales. Sin embargo, las imágenes de radar aún son difíciles de explotar debido al ruido Speckle inherente. Las características de frecuencia y polarización de los pulsos de radar incidente y los ecos retrodispersados son una elección importante. En este estudio se emplean imágenes radar en banda *C* de frecuencia porque esta banda de frecuencia proporciona un buen compromiso de propiedades, y porque existían imágenes disponibles de forma abierta en la zona gracias al programa Copernicus. Las imágenes de frecuencia más baja (banda *L*) pueden fallar en la detección de arena seca debido a la penetración del terreno y las imágenes SAR de alta resolución (banda *X*) de mayor frecuencia no estaban disponibles en el sitio de prueba. Las imágenes de radar que se usan en esta sección se describen en la tabla 5.3. La intensidad de cada píxel representa ahora la energía de microondas retrodispersada correspondiente a un píxel. Por lo tanto, la calibración radiométrica, la corrección geométrica y el registro conjunto son necesarios para hacer coincidir las imágenes ópticas en el mapa (WGS84 zona 31 norte) y el tamaño de píxel 30×30 m.

Las imágenes SAR presentan un ruido inherente causado por su ancho de banda espectral relativamente estrecho que se denomina ruido Speckle. El ruido Speckle está causado por la interferencia constructiva y destructiva de las ondas de retorno coherentes desfasadas producidas por los retrodispersados elementales aleatorios pertenecientes a cada celda de resolución. Este ruido multiplicativo perjudica la interpretación de la

información, pero su reducción también puede degradar las características de la textura en el dominio espacial. La reducción de ruido Speckle se puede aplicar mediante filtrado espacial o procesado *Multilook*. En esta sección se selecciona un filtro Speckle clásico de tipo Lee [253] con los siguientes parámetros: tamaño de ventana 3×3 , modelo multiplicativo con ruido igual a 1,0 y variación de ruido igual a 0,25. También se prueba un filtro adaptativo clásico de tipo Frost con los siguientes parámetros: tamaño de ventana 3×3 , y valor 2 como factor de amortiguamiento. La figura 5.7 muestra la imagen original en polarización VV SAR obtenida en 2015 y su resultado filtrado con el filtro de Lee y de Frost. En este estudio, los resultados proporcionados por las imágenes de radar filtradas y no filtradas se comparan adecuadamente para comprobar si resulta conveniente realizar reducción de ruido Speckle.

5.5.2 Integración de datos radar en la clasificación

Se ha elegido como punto de partida la metodología basada en el clasificador SVM por objetos, validado anteriormente en la sección 5.4. Se usa el diagrama de flujo descrito en la figura 3.2 para segmentar y clasificar las imágenes. Se emplea el mismo número reducido de clases en la leyenda que simplifica el procedimiento, ya que el objetivo es de nuevo la detección de desertificación en la misma zona. En este caso, la investigación realizada ha consistido en la búsqueda de la mejor estrategia a la hora de integrar los datos de imagen radar en la cadena de procesado por objeto. El diagrama de flujo representado en la figura 5.8 describe la manera de introducir los datos radar en el procedimiento de clasificación. Los filtros para reducir el ruido Speckle han sido evaluado en el marco del procedimiento propuesto. Diferentes canales de polarización también son evaluados. Finalmente, se ha seleccionado el mejor enfoque en términos de precisión global y coeficiente kappa para un análisis posterior.

La herramienta de extracción de características del software ENVI se emplea para la clasificación de datos por objetos. Atendiendo a este método, varios píxeles contiguos forman un objeto cuando sus valores espectrales son semejantes. Se usan las etapas descritas en el diagrama de flujo representado en la figura 3.2. En este estudio, la segmentación usa la técnica de detección de bordes con un nivel de escala de 40-45 %, un algoritmo de fusión de programa Lambda completo usando un valor de fusión de 60-65 % y un kernel de textura de 3×3 píxeles. Estos valores se obtienen después de un análisis previo para lograr el mejor resultado.

Se emplea la técnica SVM, ya que esta clasificación mejora en precisión a los demás métodos. Se elige el kernel basado en una función RBF para el clasificador SVM porque se demuestra en la sección 5.4 que ofrece los mejores resultados. El kernel RBF necesita la elección previa de dos valores, el primero es el parámetro γ , que controla el ancho

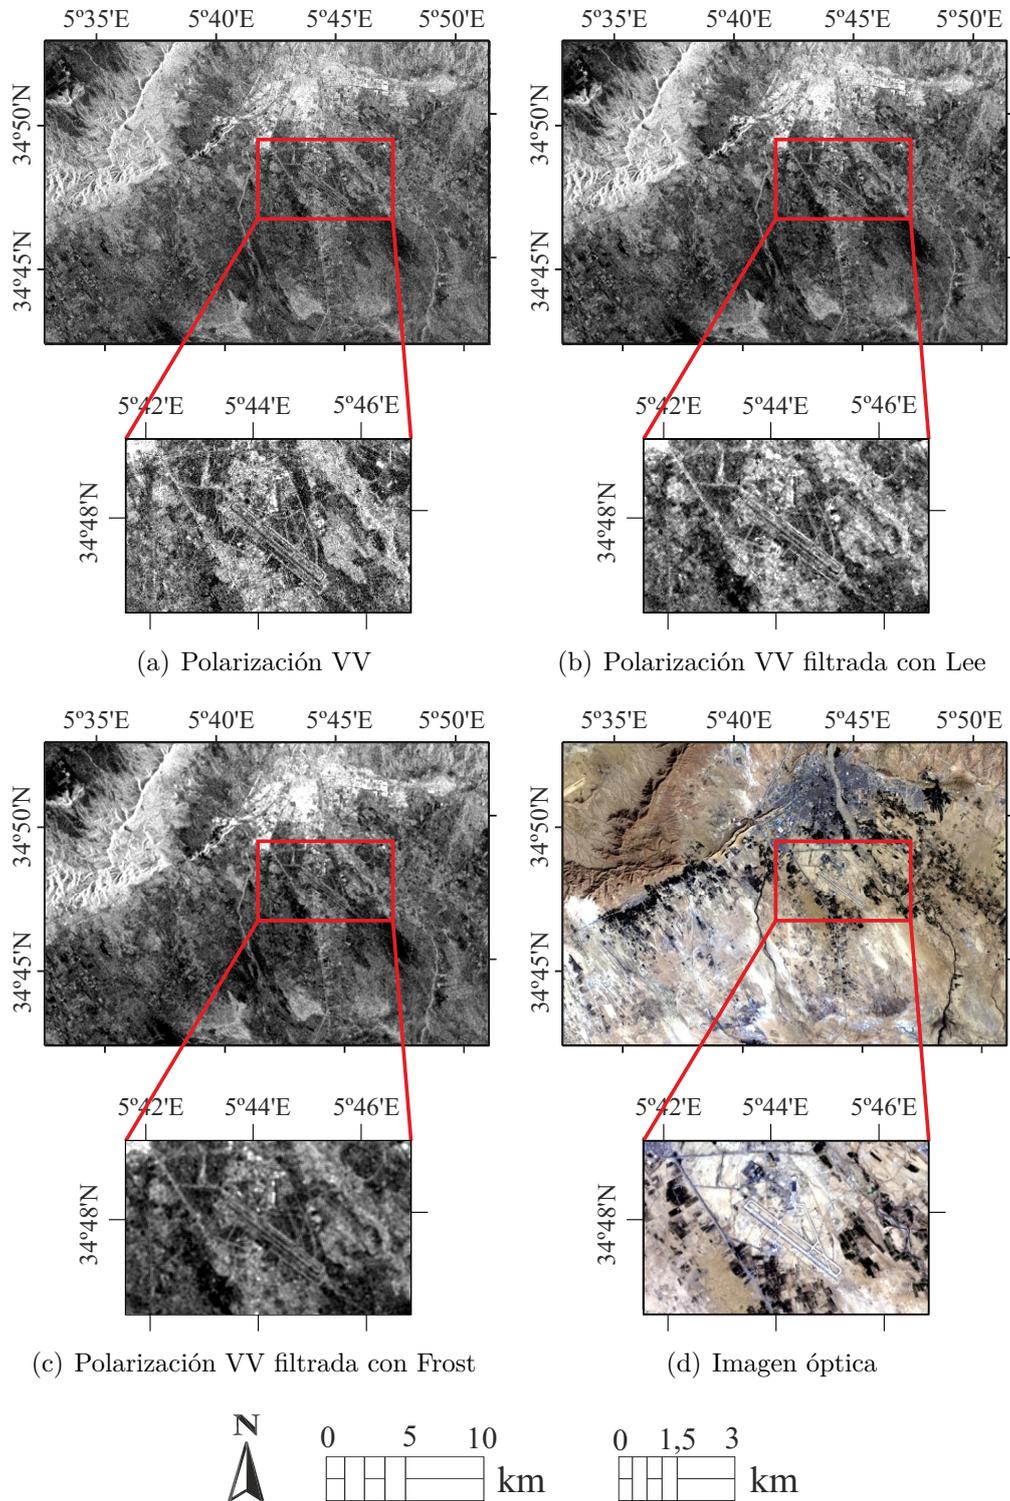


Figura 5.7: Imagen SAR e imagen óptica tomadas en 2015: imagen original VV SAR en (a), imagen VV SAR filtrada con el filtro Lee en (b), imagen VV SAR filtrada con el filtro Frost en (c) y la imagen óptica en (d).

del kernel, y el segundo es C , que gestiona el error en el algoritmo. Se extraen los valores óptimos de γ igual a 0,03 y C igual a 100 del estudio previo realizado en la sección anterior. La biblioteca para la SVM diseñada por [283] e implementada en ENVI se emplea en este método. El proceso de entrenamiento de la clasificación supervisada se basa en la selección de regiones de muestra de píxeles de cada clase. Este es un proceso clave llevado a cabo por un operador humano. Con esta metodología, se seleccionan 328 grupos de píxeles de entrenamiento para la imagen de 2015, y 500 agrupaciones de píxeles se seleccionan para la imagen de 2016. Se emplean las seis clases seleccionadas previamente, que se muestran en la tabla 5.4. Esta selección facilita el procedimiento de clasificación para el estudio de la desertificación.

Existen diferentes estrategias para extraer la información de las imágenes ópticas y de radar en el proceso de clasificación SVM. Algunas combinaciones de ellas se prueban y se comparan en este estudio. La figura 5.8 muestra la técnica estándar de referencia para la comparación. Esta metodología de base, presentada en la sección 5.4, utiliza solo los datos ópticos y se emplea para comparar. La idea de añadir datos radar busca mejorar la detección de la desertificación. Para ello se escogen imágenes SAR de Sentinel-1A, que ayudan a cuantificar movimientos de arena causados por altas temperaturas, bajos porcentajes de humedad, y fuertes velocidades de viento. Para poder aprovechar toda esta información se ha desarrollado un estudio comparativo (ver figura 5.8) para saber en que punto de todas las etapas de detección de cambio es más conveniente añadir la imagen radar, y que tipo de imagen radar ofrece los mejores resultados. A continuación, se presentan las posibles estrategias para integrar los datos SAR:

1. La metodología estándar de base usa las bandas de Landsat para la segmentación y la clasificación supervisada (ver Algoritmo 1).
2. La segunda metodología combina las bandas ópticas e imágenes SAR con distintas características polarimétricas:
 - a) Imágenes SAR solo en polarización VV, solo polarización VH o ambas (VV, VH); además de las imágenes en el espectro óptico se utilizan en el proceso de segmentación y en la clasificación. (método (a), ver Algoritmo 2).
 - b) Las imágenes SAR no se utilizan en el proceso de segmentación, pero las imágenes SAR solo en polarización VV, solo polarización VH o ambas (VV, VH) junto con los datos ópticos se utilizan para clasificar. (método (b), ver Algoritmo 3).
 - c) Se aplica un filtro Speckle (Lee, Frost) a cada imagen SAR de cada polarización (VV y VH), y luego estas imágenes filtradas (solo VV, solo VH o ambas) se

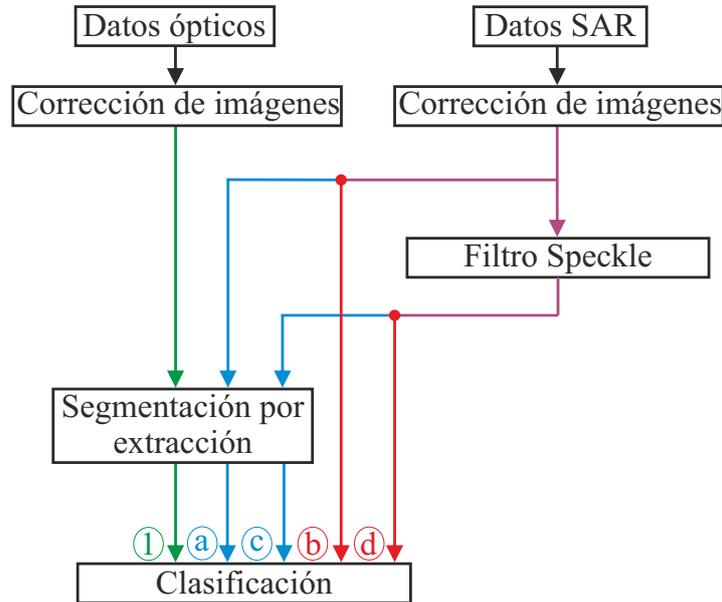


Figura 5.8: Diagrama de flujo que muestra los diferentes algoritmos para la clasificación de datos ópticos (1) y combina imágenes ópticas y SAR (a-d).

usan junto con los datos ópticos en los procesos de segmentación y clasificación. (método (c), ver Algoritmo 2).

- d) Se aplica un filtro Speckle (Lee, Frost) a cada imagen SAR de cada polarización (VV y VH), pero estas imágenes filtradas (solo VV, solo VH o ambas) se usan junto con los datos ópticos en el proceso de clasificación. (método (d), ver Algoritmo 3).

Algorithm 1 Clasificación estándar, método (1)

- 1: Corrección geométrica y radiométrica
 - 2: Registro
 - 3: Segmentación y clasificación SVM
 - 4: Comparación con los datos de referencia
 - 5: Cálculo de PG , CK
-

Algorithm 2 Fusión del SAR y el óptico. Incluyendo los datos SAR **antes** de la segmentación, $sf=0$ por el método (a), $sf=1$ por el método (c)

```
1: SAR(1)=VV, SAR(2)=VH, SAR(3)=(VV,VH)
2: Corrección geométrica y radiométrica
3: Registro
4: if  $sf=1$  then Aplicar el filtro Speckle
5: end if
6: for  $i = 1$  to 3 do
7:   Selección de la polarización SAR( $i$ )
8:   Segmentación y clasificación SVM
9:   Comparación con los datos de referencia
10:  Cálculo de  $PG$ ,  $CK$ 
11: end for
```

Algorithm 3 Fusión del SAR y el óptico. Incluyendo los datos SAR **después** de la segmentación, $sf=0$ por el método (b), $sf=1$ por el método (d)

```
1: SAR(1)=VV, SAR(2)=VH, SAR(3)=(VV,VH)
2: Corrección geométrica y radiométrica
3: Registro
4: if  $sf=1$  then Aplicar el filtro Speckle
5: end if
6: Segmentación de datos ópticos
7: for  $i = 1$  to 3 do
8:   Selección de la polarización SAR( $i$ )
9:   Clasificación SVM
10:  Comparación con los datos de referencia
11:  Cálculo de  $PG$ ,  $CK$ 
12: end for
```

5.5.3 Resultados de la clasificación y discusión

La primera tarea es establecer el mejor método para clasificar la imagen teniendo en cuenta las diferentes fuentes de datos SAR (polarizaciones VV, VH o ambas), la etapa en la que se incluyen los datos SAR en la cadena de procesamiento (antes o después de segmentación), y el uso de un filtro Speckle (filtrado o no), como se propuso en la sección 5.5.2. Todas estas posibilidades se evalúan utilizando un análisis de precisión de clasificación en regiones seleccionadas visualmente para validación. Estas áreas de validación son diferentes a las regiones de entrenamiento utilizadas en la clasificación supervisada. Para este proceso de validación, 7933 píxeles aleatorios se clasifican visualmente, cubriendo 7,14 km² de área verificada (1,29 % de toda la zona de estudio). El coeficiente kappa (CK) y la precisión global (PG) se calculan para cada una de las metodologías propuestas. La

tabla 5.18 muestra todos los resultados de este análisis. El peor resultado lo proporciona el método que utiliza los datos SAR de polarización VH filtrada con Frost antes la etapa de segmentación y clasificación, con un 73,78 % de precisión global en los datos de 2015. La mejor metodología es producida por el método que usa la imagen SAR en polarización VV sin filtrado de Speckle después del paso de segmentación. Esta opción proporciona un 97,05 % de precisión total y el 0,96 de coeficiente kappa en 2015, y un 96,57 % de precisión global y el 0,96 de coeficiente kappa en los datos de 2016.

Tabla 5.18: Resultados de clasificación de los diferentes métodos.

Método de clasificación	2015		2016	
	PG	CK	PG	CK
Óptico (1)	86,82	0,83	89,90	0,87
VV antes de segmentar (a)	87,28	0,84	90,18	0,88
VV después de segmentar (b)	97,05	0,96	96,57	0,96
VV con filtro Lee antes de segmentar (c)	83,18	0,78	86,12	0,83
VV con filtro Lee después de segmentar (d)	84,74	0,80	89,77	0,87
VV con filtro Frost antes de segmentar (c)	81,87	0,77	82,69	0,78
VV con filtro Frost después de segmentar (d)	82,13	0,77	84,51	0,81
VH antes de segmentar (a)	86,13	0,82	87,38	0,84
VH después de segmentar (b)	86,90	0,83	89,15	0,86
VH con filtro Lee antes de segmentar (c)	75,94	0,69	85,49	0,82
VH con filtro Lee después de segmentar (d)	81,92	0,77	86,75	0,83
VH con filtro Frost antes de segmentar (c)	73,78	0,67	82,57	0,78
VH con filtro Frost después de segmentar (d)	80,72	0,75	85,21	0,82
Dual polarization (DV) antes de segmentar (a)	84,74	0,80	88,19	0,85
DV después de segmentar (b)	87,52	0,84	90,41	0,88
DV con filtro Lee antes de segmentar (c)	79,73	0,74	86,02	0,83
DV con filtro Lee después de segmentar (d)	85,32	0,81	87,03	0,84
DV con filtro Frost antes de segmentar (c)	76,90	0,71	83,22	0,79
DV con filtro Frost después de segmentar (d)	82,12	0,77	84,60	0,81

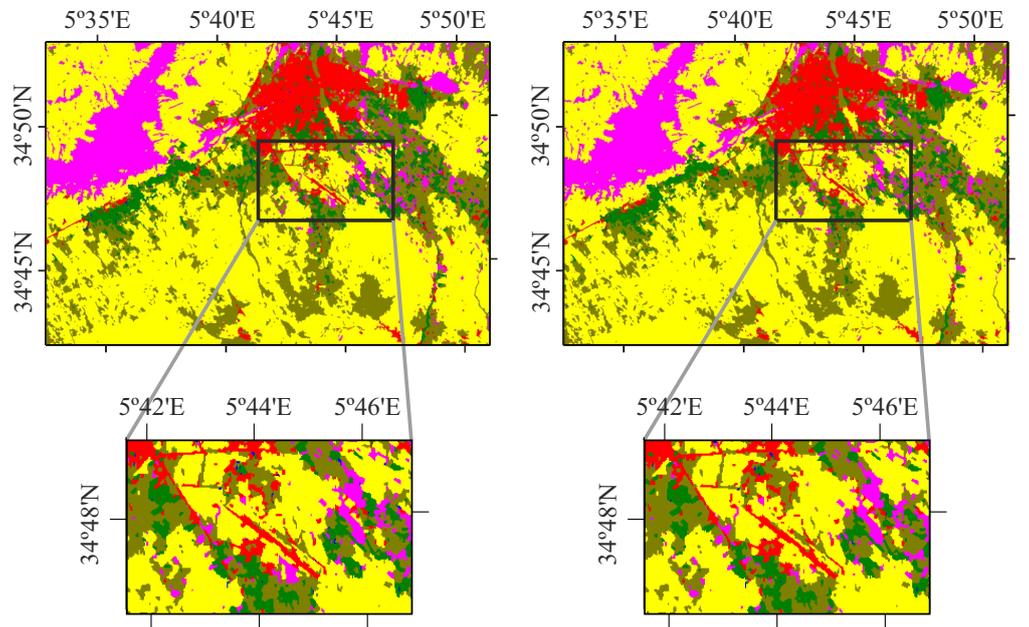
De estos resultados queda claro que la mejor estrategia es considerar los datos SAR solo para clasificar. Los procesos de segmentación que utilizan información SAR (en cualquiera de sus polarizaciones) ofrecen resultados peores que las técnicas que no utilizan datos SAR para la segmentación en todos los casos. Esto se debe al poco detalle espacial que proporcionan las imágenes SAR en comparación con los datos ópticos de resolución espacial similar debido al ruido y a otras características propias de estas imágenes. También se demuestra que el filtrado Speckle no es conveniente para nuestro propósito, porque reduce el ruido pero también reduce la información de textura de la imagen SAR, que es muy útil en la etapa de clasificación. Además, se puede demostrar que los mejores

resultados vienen dados por el canal de polarización VV, ya que la inclusión del canal de polarización VH no mejora el resultado final. Por lo tanto, queda claro que la metodología que supera claramente al resto viene dada por la metodología (b) que usa solo la polarización VV sin filtrado Speckle.

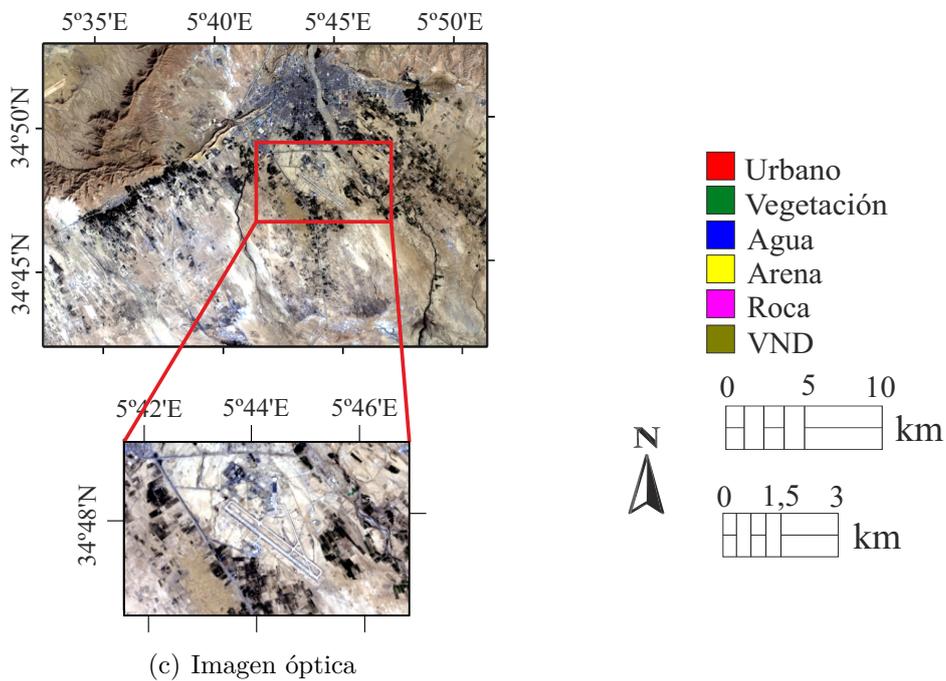
En la figura 5.9 se muestra el resultado gráfico obtenido para la clasificación del conjunto de 2015, utilizando el método estándar de base empleando solo datos ópticos (1) y la mejor metodología (b) utilizando la polarización VV sin filtrado. Las tablas 5.19 y 5.20 muestran las matrices de confusión dadas por la clasificación estándar de datos ópticos en 2015 y 2016, respectivamente. Las tablas 5.21 y 5.22 muestran las matrices de confusión proporcionadas por la mejor metodología, incluidos los datos SAR de 2015 y 2016, respectivamente. Los resultados de la clasificación son mucho más precisos al usar imágenes SAR en el proceso de clasificación. La precisión global aumenta con éxito del 86,82% (metodología de base solo óptica) al 97,05% en el conjunto de datos de 2015 gracias a la inclusión de los datos de radar. Se debe señalar que la clase que arroja los peores resultados es el agua, que no es muy frecuente en la escena. Por el contrario, la arena se caracteriza de forma excelente. La mejor metodología de clasificación seleccionada se utiliza a continuación en un análisis de desertificación más profundo en la ciudad de Biskra empleando detección de cambio.

Tabla 5.19: Matriz de confusión de la clasificación en 2015 utilizando el método estándar (1).

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1327	0	0	0	15	4	1,41 %
	Vegetación	14	1039	32	0	0	120	13,78 %
	Agua	2	3	24	0	0	0	17,24 %
	Arena	11	0	0	1222	23	10	3,48 %
	Roca	97	10	0	78	1860	4	9,22 %
	VND	120	357	4	85	56	1416	30,52 %
	Error de omisión	15,53 %	26,26 %	60,00 %	11,77 %	4,81 %	8,88 %	
Precisión global 86,82%, coeficiente kappa 0,83								



(a) Resultados de la clasificación con el método (1) (b) Resultados de la clasificación con el método (b), polarización VV



(c) Imagen óptica

Figura 5.9: Resultados de la clasificación en datos de 2015 con zoom: utilizando el método (1) en (a), utilizando el método (b) y polarización VV en (b), imagen óptica en (c).

Tabla 5.20: Matriz de confusión de la clasificación en 2016 utilizando el método (1).

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1422	19	3	0	89	7	7,66 %
	Vegetación	32	1367	15	0	0	109	10,24 %
	Agua	0	4	19	0	0	2	24,00 %
	Arena	60	0	0	1310	193	7	16,56 %
	Roca	36	6	2	47	1672	87	9,62 %
	VND	21	7	28	27	0	1342	5,82 %
	Error de omisión	9,48 %	2,57 %	71,64 %	5,35 %	14,43 %	13,64 %	
Precisión global 89,90 %, coeficiente kappa 0,87								

Tabla 5.21: Matriz de confusión de la clasificación en 2015 utilizando el método (b) y la imagen SAR de polarización VV.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1462	0	0	0	0	4	0,27 %
	Vegetación	14	1386	51	0	0	9	5,07 %
	Agua	0	3	5	0	0	0	37,50 %
	Arena	9	0	0	1365	0	10	1,37 %
	Roca	2	13	0	0	1954	4	0,96 %
	VND	84	7	4	20	0	1527	7,00 %
	Error de omisión	6,94 %	1,63 %	91,67 %	1,44 %	0,00 %	1,74 %	
Precisión global 97,05 %, coeficiente kappa 0,96								

Tabla 5.22: Matriz de confusión de la clasificación en 2016 utilizando el método (b) y la imagen SAR de polarización VV.

Clase		Suelo verdadero (píxeles)						Error de comisión
		Urbano	Vegetación	Agua	Arena	Roca	VND	
Imagen clasificada	Urbano	1473	9	3	0	19	3	2,26 %
	Vegetación	12	1377	4	0	0	17	2,34 %
	Agua	0	4	53	0	0	2	10,17 %
	Arena	46	0	0	1310	14	0	4,38 %
	Roca	9	6	2	47	1921	5	3,47 %
	VND	31	7	5	27	0	1527	4,38 %
	Error de omisión	6,24 %	1,85 %	20,90 %	5,35 %	1,69 %	1,74 %	
Precisión global 96,57 %, coeficiente kappa 0,96								

5.5.4 Detección de cambio

Para la detección de cambio se emplea la misma técnica de comparación post-clasificación descrita en la sección 5.4. La precisión de detección de cambio se basa de nuevo en las etiquetas de la clasificación realizada sobre cada imagen. En este estudio, la evaluación de la detección de cambio se aplica al par de imágenes adquiridas en 2015 y 2016, porque no se dispone de un archivo de imágenes SAR tan grande como el que estaba disponible en el archivo de Landsat. Posteriormente, se obtienen los índices de cambio más adecuados para la interpretación del cambio de la cobertura terrestre, de entre los que se describen en la subsección 3.4.

5.5.5 Resultados de detección de cambio y discusión

Aquí se evalúa el cambio con la matriz de transición LULC. La tabla 5.23 muestra la matriz de transición para el par de imágenes 2015-2016. La diagonal de la matriz de los cambios proporciona la persistencia de cada clase, y los valores que no pertenecen a la diagonal muestran el tipo de transición en las clases en ese período. El cambio de 2015 a 2016 se muestra en la tabla de transición LULC, con un cambio mayoritario de arena a vegetación no densa, que representa el 7,89 % del cambio. Esto se explica por la migración de arena al norte de Biskra. Además es consistente con el viento habitual, que está representado en la figura 5.4, en él la velocidad más alta y la dirección predominante del viento ocurre hacia el noroeste. La transición de la clase roca a arena es 2,14 % del cambio, y el cambio de urbano a arena presenta una proporción del 0,67 %. Hay una pequeña cantidad de vegetación convertida en arena con un 0,10 % del cambio. La clase de arena es claramente dominante con el 54,48 % de la superficie total en 2016.

Tabla 5.23: Matriz de transición LULC (%) de 2015 a 2016.

2015-2016	Urbano	Vegetación	Agua	Arena	Roca	VND	Total 2016	Ganancia
Urbano	4,56	0,15	0,01	0,24	0,08	0,59	5,62	1,06
Vegetación	0,11	4,02	0,03	0,09	0,12	0,83	5,20	1,18
Agua	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01
Arena	0,67	0,10	0,00	46,63	2,14	4,93	54,48	7,85
Roca	0,22	0,09	0,00	1,36	6,69	0,55	8,92	2,22
VND	1,53	1,51	0,04	7,89	1,29	13,41	25,66	12,25
Total 2015	7,09	5,87	0,09	56,20	10,33	20,31	100	24,58
Pérdida	2,53	1,85	0,09	9,58	3,63	6,90	24,58	

El índice de cambio es la herramienta útil para caracterizar la dinámica de clase en un período de tiempo. La tabla 5.24 muestra los índices definidos en la sección 3.4 para cada clase en el intervalo de tiempo de 2015 a 2016. La clase de arena y la clase de vegetación no densa presentan valores altos de ganancia con un 7,85 %, y un 12,25 %, respectivamente y una pérdida del 9,58 % y del 6,90 %, respectivamente. Esto significa que estas clases son muy dinámicas en el mapa de cambio general. La arena y vegetación no densa también muestran valores altos de swap con un 15,71 % y un 13,81 %, respectivamente, comparado con las otras clases. Esto sucede porque estas clases están afectadas en mayor grado por el movimiento de la arena. Las dunas de arena son abundantes en el suroeste de Biskra, y son la causa principal de la desertificación. La clase de agua apenas cambia con un cambio neto del 0,08 % y un swap del 0,02 %, debido a su pequeña contribución en la escena general.

Tabla 5.24: Índices de cambio de LULC entre 2015 y 2016 (%).

Clases	Total 2015	Total 2016	Ganancia	Pérdida	Persistencia	Cambio total	Swap	Cambio Neto
Urbano	7,09	5,62	1,06	2,53	4,56	3,59	2,12	1,47
Vegetación	5,87	5,20	1,18	1,85	4,02	3,03	2,36	0,67
Agua	0,09	0,01	0,01	0,09	0,00	0,10	0,02	0,08
Arena	56,20	54,48	7,85	9,58	46,63	17,43	15,71	1,72
Roca	10,33	8,92	2,22	3,63	6,69	5,86	4,45	1,41
VND	20,31	25,66	12,25	6,90	13,41	19,15	13,81	5,34
Total	100	100	24,58	24,58	75,31	49	38,47	10,69

Incluso para un período corto de un año, hay un cambio considerable en Biskra. El cambio de la cobertura del suelo es notable para la arena y las clases de vegetación no densa. El porcentaje de área sin cambio desde 2015 hasta 2016 es del 75,31 %. Por lo

tanto, hay algún tipo de cambio en el 24,58 % de la superficie.

También se calculan algunas relaciones entre índices, ya que son muy útiles en la evaluación de detección de cambios. La relación de pérdida a persistencia l_p es una de las más interesantes. Si l_p es mayor que 1, la clase corre una probabilidad mayor de cambiar a otra clase que de persistir. Todas las clases presentan valores de l_p inferiores a 1, mostrando baja probabilidad de cambio por la corta duración de estudio. El porcentaje de cambio muestra el potencial para el cambio general de una clase. En la tabla 5.25 se muestra que el porcentaje de cambio para la clase arena tiene una pérdida del 1,72 %, y la vegetación no densa una ganancia del 5,00 %, lo que confirma una transición de arena a vegetación no densa en ese periodo de tiempo de un año. Es importante realizar estudios con un periodo de tiempo mayor, que ofrecen un mapa de cambio más fiable y se pueden observar las tendencias a largo plazo. En resumen, la combinación del índice l_p y el porcentaje de cambio son herramientas muy relevantes para controlar la degradación de la tierra, que es un factor clave en la desertificación.

Tabla 5.25: Índice de pérdida a persistencia l_p , y porcentaje de cambio en el período de 2015 a 2016.

Clases	l_p	Porcentaje de cambio (%)
Urbano	0,55	-1,47
Vegetación	0,46	-0,67
Agua	0,00	-0,08
Arena	0,21	-1,72
Roca	0,54	-1,41
VND	0,51	5,00

La calidad de todo el proceso se evalúa mediante el coeficiente kappa y la precisión global. Como en los procedimientos de validación anteriores, el conjunto de datos de verificación es diferente de los píxeles de entrenamiento para obtener una evaluación rigurosa. Se eligen 13,45 km² (2,43 % de la superficie total) de los datos de referencia del terreno con 7651 píxeles no cambiados y 7297 píxeles cambiados, mediante inspección visual. La matriz de confusión de cambio/no-cambio obtenida utilizando los datos en 2015 y 2016 se muestra en la tabla 5.26 y la tabla 5.27. Los resultados son excelentes, con una precisión global igual a 95,29 % y un coeficiente kappa de 0,91, empleando la metodología escogida que clasifica con la técnica SVM por objetos con la inclusión de la imagen SAR en polarización VV sin filtrado Speckle después de la segmentación (método (b) usando polarización VV, algoritmo 3). La clasificación óptica estándar de base (método (1), algoritmo 1) muestra un coeficiente kappa de 0,84 y una precisión global igual a 91,99 %. Estos resultados muestran la gran mejora que introduce el nuevo método de clasificación en Biskra utilizando el conjunto de imágenes Landsat-8 y Sentinel-1A.

Tabla 5.26: Matriz de confusión usando los datos ópticos y el algoritmo 1.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	6881	427	7308	5,84 %
	Píxeles cambiados	770	6870	7640	10,08 %
	Total	7651	7297	14948	
	Error de omisión	10,06 %	5,85 %		
Precisión global 91,99 %, coeficiente kappa 0,84					

Tabla 5.27: Matriz de confusión de cambio usando la mejor metodología: técnica (b), algoritmo 3 usando polarización VV sin filtro Speckle.

Numero de píxeles		Referencia			
		Píxeles no-cambiados	Píxeles cambiados	Total	Error de comisión
Imagen clasificada	Píxeles no-cambiados	7403	456	7859	5,80 %
	Píxeles cambiados	248	6841	7089	3,50 %
	Total	7651	7297	14948	
	Error de omisión	3,24 %	6,25 %		
Precisión global 95,29 %, coeficiente kappa 0,91					

La figura 5.10 muestra la distribución espacial de las transiciones de clases para el análisis 2015-2016. Se aprecian gran cantidad de píxeles que cambian debido al desplazamiento de arena con el viento dominante del sureste del Sahara (ver figura 5.4). En Biskra, se observa de nuevo que la combinación de la orografía y los flujos de viento impulsan una importante cantidad de arena hacia las estribaciones del Atlas. La figura 5.10 muestra el cambio de clase desde 2015 hasta 2016, donde el color marrón representa el cambio de otras clases a arena. Esta figura muestra una tendencia muy dinámica, en un año de observación se aprecia el comienzo de un grave proceso de desertificación en el norte de Biskra. La transformación de arena a vegetación no densa es causada principalmente por actividades agrícolas humanas.

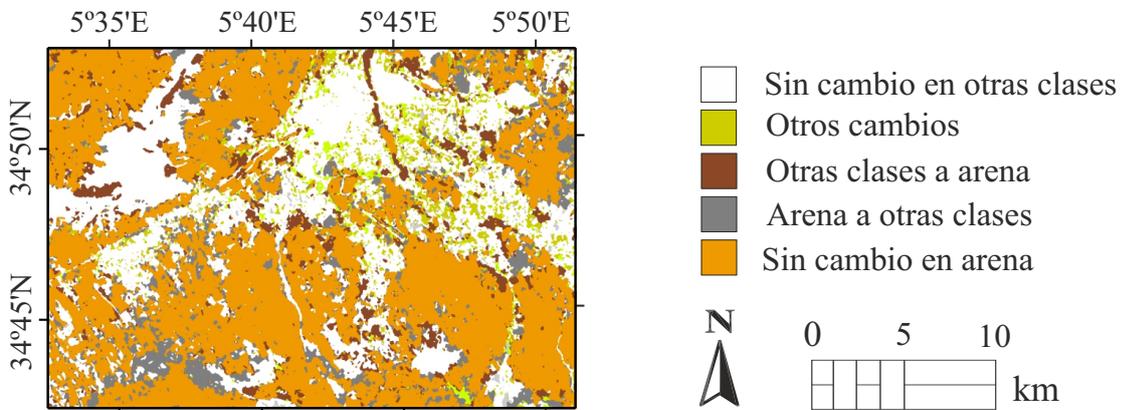


Figura 5.10: Distribución del LULC entre 16-03-2015 y 02-03-2016.

En este estudio, se ha diseñado la mejor metodología para incluir datos SAR en un algoritmo de base desarrollado en la parte 5.4. Se ha aplicado en la evaluación de la desertificación en los alrededores de Biskra (Argelia) durante un período de un año utilizando datos disponibles gratuitamente de Landsat-8, Sentinel-1A e información local. Se elige Biskra porque está claramente bajo riesgo de desertificación debido a su proximidad al Sahara, su viento predominante y su topografía. La metodología se basa en la detección de cambio con clasificación posterior usando datos ópticos Landsat y la clasificación SVM por objeto. Las bandas SAR no pueden tratarse en el procedimiento como bandas ópticas adicionales debido a sus propiedades claramente diferentes. Por esa razón, se presenta un estudio comparativo y se obtienen algunas conclusiones importantes. En primer lugar, se ha demostrado que el mejor enfoque es omitir las imágenes de microondas para el proceso de segmentación. El ruido inherente que está presente en las imágenes de radar no ayuda en el paso de definición del objeto. Sin embargo, el contenido de la imagen de radar se usa para definir las reglas de clasificación después de la segmentación y es importante su

uso en los atributos de textura. También se ha demostrado que los filtros de reducción de ruido Speckle (Lee, Frost) no ayudan en el procedimiento de clasificación, ya que se reduce el ruido Speckle y eliminan a su vez información importante de textura y de detalle. El estudio finalmente muestra que el uso de la banda polarizada cruzada (VH) no mejora el resultado final en este caso.

Se ha demostrado que la imagen SAR ha mejorado notablemente la calidad de los resultados, puesto que es una herramienta muy valiosa para distinguir suelo con arena de entre otros tipos de suelo natural. Además, los datos de microondas se adquieren en todas las condiciones climáticas, y la programación de adquisiciones se facilita por ello. La calidad del análisis ha sido rigurosamente evaluada por las matrices de confusión de los resultados de las clasificaciones y de la detección de cambios. Además, se logran resultados excelentes con un pequeño conjunto de datos de entrenamiento.

Conclusiones y líneas futuras

6.1 Conclusiones

En esta Tesis se han estudiado distintos aspectos relacionados con la metodología de procesado de imágenes de media resolución para la detección de cambio en el uso de suelo. Se propone una nueva metodología para detección de desertificación, incluyendo datos ópticos y de radar. Esta metodología se ha aplicado en una zona de Argelia amenazada por el problema de la desertificación. En esta Tesis se desarrollan nuevas técnicas para analizar las imágenes del satélite y la interpretación del cambio ocurrido mediante la integración de información adicional. De forma más concreta, se usan técnicas de teledetección para procesar imágenes de distinto tipo para producir un mapa de distribución del cambio de suelo. Los resultados obtenidos permiten confirmar que la fusión de datos ópticos y de radar es indispensable para mejorar la precisión de detección de cambios de forma semiautomática.

El fin principal de esta Tesis definido en la sección 1.1 consiste en el desarrollo de un método semiautomático para mejorar la precisión de detección de uso del suelo mediante la fusión de informaciones de distintas fuentes. El trabajo a realizar en el marco de esta Tesis se relaciona con tres grandes objetivos 1, 2 y 3.

Para lograr el objetivo 1 de la tesis, primero se comparan diferentes clasificadores supervisados que trabajan por píxel para proporcionar un mapa de probabilidad posterior para cada imagen. Estos clasificadores supervisados permiten caracterizar los datos y asignar cada elemento a una de las clases de estudio. De este modo, los resultados de la clasificación muestran que el MLC es el método más preciso en nuestro caso, por lo que ha

sido seleccionado para llevar a cabo la primera parte de esta Tesis. Se ha usado la técnica SCVAPS para la detección de cambios junto con el algoritmo DFPS para la búsqueda del mejor umbral en dos áreas de interés (Distrito de Shunyi, Pekín, China y en Aïn Defla, Argelia). Se comprueba que los resultados del método DFPS dependen en gran manera de las muestras de entrenamiento, la experiencia y las habilidades del analista. Se discrimina el cambio con el uso del mapa de probabilidad posterior y el ángulo entre el vector real y el teórico. Las técnicas usadas resultan de gran utilidad en la detección de cambios, ya que los resultados muestran alta precisión en los resultados de cambio/no-cambio (91,85 % en Pekín y 93,96 % en Aïn Defla), a pesar de que sus dinámicas de cambio son muy diferentes. La calidad de los datos juega un papel muy importante en el proceso de detección, ya que la adquisición de datos debe hacerse en diferentes años eligiendo la misma temporada. Esta técnica ha podido detectar la alta dinámica de la zona de China por la planificación y ordenación territorial de la ciudad, y también ha mostrado fielmente la detección de los pocos cambios naturales en Argelia. El uso de las tablas detalladas permite comprender el cambio en uso de suelo a nivel regional o global. En este primer estudio se demuestra la alta efectividad del método gracias en parte a la buena implementación de las etapas de corrección de imagen y registro, y por otra parte se comprueba la complejidad que entraña la búsqueda del umbral óptimo mediante el algoritmo DFPS. También sirve para conocer las ventajas e inconvenientes de la implementación.

Para verificar el alcance del objetivo 2, se tiene en cuenta el problema de desertificación y su rápida evolución y por la dificultad por parte de las autoridades gubernamentales argelinas en la lucha contra ella. Asimismo, se desarrollan técnicas de detección de la desertificación con bajo coste. Para ello se usan datos ópticos del satélite Landsat 5, el modelo digital de elevación y datos ambientales. Se comparan distintos modos de clasificación (por píxel y por objetos) y diferentes clasificadores supervisados. Se emplea un pequeño número de clases para simplificar el procedimiento. Los resultados de la clasificación indican que el clasificador SVM supervisado por objetos alcanza la mejor precisión y explota de forma óptima los atributos espectrales, espaciales y de textura. En este resultado influye en gran manera el número y el tipo de clases seleccionadas y el conocimiento del área de interés por parte del analista. También se comparan distintos métodos de detección de cambios: CVAPS y PCC. Los resultados en forma de matrices de confusión para detección de cambio indican que el método PCC logra la mejor precisión con la ventaja adicional de evitar la compleja selección de las ventanas dobles para la búsqueda del umbral óptimo, proporcionando así más recursos de operador para obtener una mejor clasificación. Este clasificador y el método de detección de cambio se seleccionan para llevar a cabo el siguiente objetivo de la Tesis. Se consigue así presentar una metodología semiautomática para evaluar los movimientos de la arena durante 25 años. En el caso de detección de cambio a largo plazo es más conveniente usar el método PCC, porque así se

evita la búsqueda de umbral óptimo entre todos los pares de imágenes. De esta manera se reduce ostensiblemente el tiempo de procesado. Se obtienen las matrices de transición, y diferentes índices de cambio. Los resultados se presentan también con mapas de cambio entre los pares de imágenes usadas en el estudio. Los resultados indican que el cambio de la vegetación no densa a arena es el más representativo, causado por el viento junto con otros factores tales como las altas temperaturas, la baja humedad y la topografía que favorece el desplazamiento de las partículas de arena. Esto ocasiona una grave degradación de áreas críticas, que incluyen campos de cultivo. Por lo tanto, se puede deducir que el viento es el principal factor en el transporte de partículas de arena a las zonas áridas en el noroeste de Biskra. Se obtiene una precisión muy buena con una baja cantidad de píxeles de entrenamiento, lo que demuestra la efectividad del método con un bajo coste en tiempo de operador humano. El mapa de la distribución del cambio presenta un soporte muy interesante para supervisar la evolución de la desertificación con un soporte gráfico. Además, los índices y sus relaciones son fácilmente interpretables por un usuario final. Con este método se obtienen buenos resultados que validan la aplicación del método existente a la nueva zona objeto de estudio, satisfaciendo el objetivo correspondiente de la Tesis. Sin embargo, se busca mejorar la precisión y encontrar una metodología óptima que sea capaz de integrar datos de tipo radar en la cadena de procesado.

Se usan datos ópticos, a los que se añaden imágenes SAR en banda C de frecuencia en sus polarizaciones VV, VH, y DV. Se evalúa el uso de un filtro Speckle (Lee, Frost) que permita reducir el ruido Speckle. También se desarrolla la mejor metodología para incluir los datos de radar en la cadena de procesado diseñado previamente, que utiliza únicamente datos ópticos. Se incluyen imágenes de microondas (polarizaciones VV, VH, DV), con y sin filtrado (Lee, Frost), antes y después de la etapa de segmentación. Se selecciona el clasificador por objetos SVM, puesto que se identifica en el estudio previo como el que proporciona los mejores resultados de clasificación en la zona. La cadena de procesado que integra la imagen en polarización VV sin filtrado Speckle después de la fase de segmentación presenta el mejor resultado respecto a la precisión global y el coeficiente kappa en los resultados de la clasificación. Este método proporciona los mejores resultados porque consigue integrar la valiosa información en frecuencias de microondas sin perjudicar la etapa de segmentación debido a la falta de detalle espacial y a la presencia de ruido Speckle. La ventaja al añadir los datos SAR al proceso es que mejora la precisión de la detección de desertificación y complementa la información obtenida del suelo. La rugosidad del suelo y su humedad se caracterizan claramente mejor en las longitudes de onda correspondiente al rango de las microondas. Por ello, la arena se caracteriza de forma excelente. Incluso para un período corto de un año, hay un cambio considerable (un cuarto de la zona estudiada) en las clases arena y vegetación no densa. En un año de observación se aprecia el comienzo de un grave proceso de desertificación en el norte

de Biskra. Este método se demuestra claramente superior a la estrategia de emplear la imagen de radar suavizada como un canal extra en la cadena de procesado. La detección de cambio se evalúa con la matriz de confusión cambio/no-cambio y se obtienen resultados excelentes para el nuevo método con respecto a la mejor técnica que solo emplea datos ópticos (91,99 % con el método óptico y 95,29 % con el enfoque propuesto). El mapa de distribución del cambio y los índices son de nuevo factores relevantes para estudiar la desertificación por la parte de las autoridades. Por tanto, se ha cumplido con éxito el objetivo 3 de la Tesis. Este objetivo puede servir para definir la estrategia de fusión de datos radar en otras muchas aplicaciones que ya dispongan de una cadena de procesado empleando datos ópticos.

Este enfoque que usa datos de libre acceso es muy útil para las autoridades nacionales e internacionales, ya que la desertificación es un problema de alcance global. El método desarrollado tiene un especial interés para los investigadores que desean monitorizar los procesos de desertificación. Las autoridades podrían aprovechar esta información para evaluar el cambio sufrido y estimar el cambio futuro. De hecho, se pueden proponer soluciones más ajustadas al problema si se conocen las estadísticas del cambio. Este análisis también puede tener en cuenta el parámetro del cambio climático global para realizar distintas proyecciones en el tiempo, que pueden contribuir de forma significativa al desarrollo sostenible, económico y social.

En conclusión, los objetivos principales inicialmente propuestos para esta Tesis doctoral se han logrado con éxito. Como resultado, se han obtenido distintas publicaciones internacionales en revistas de carácter científico-técnico y conferencias, tal como se resume en el apéndice A.

6.2 Líneas futuras de investigación

Los estudios realizados en esta Tesis han abierto varias líneas de investigación en distintos ámbitos. En primer lugar, se puede aplicar la metodología desarrollada a distintos tipos de datos. También se podría aplicar la metodología a distintos escenarios. Finalmente, existen etapas de la metodología que podrían mejorarse tales como el proceso de segmentación.

En primer lugar, se podrían aplicar las técnicas de fusión de datos ópticos y de radar para detección de cambio con otros tipos de sensores tales como el Sentinel-2 y el Sentinel-3. Sensores con resoluciones mayores a las que se han usado en esta Tesis podrían generar clasificaciones de muy alta resolución espacial. En consecuencia, se podría obtener más información de interés y alcanzar mejor precisión de detección de cambios en una gran variedad de aplicaciones que requieran una buena resolución espacial. La disponibilidad de

imágenes de bajo coste, tales como imágenes aéreas, imágenes de drones, *Light Detection and Ranging (LiDAR)* u otros sensores embarcados en plataformas espaciales extiende el campo de tipos de información. La inclusión de las imágenes SAR en este escenario podría añadir información valiosa a la clasificación por su independencia de la presencia de nubes en la escena. En segundo lugar, se podrían identificar otras aplicaciones semejantes en cuanto a resolución espacial y tamaño de leyenda en las que se podría aplicar una metodología semejante a la diseñada en esta Tesis.

En cuanto los métodos de clasificación por objetos, se podrían mejorar distintas etapas de la metodología. En el caso de la segmentación, se podría añadir al proceso nuevas características descriptivas añadidas por el analista. El clasificador SVM ha demostrado su gran utilidad al lograr los mejores resultados de clasificación. Por ello resulta de gran interés profundizar en el proceso de la segmentación y aplicarlo a otros tipos de degradación de la tierra en otros entornos (urbanos, forestales, suelos agrícolas). Estas características añadidas proporcionan información valiosa de los objetos y sub-objetos de los segmentos de la imagen. El uso de una mayor resolución de imágenes permite además una definición correcta de los objetos y sub-objetos, lo que permite obtener una detección de cambios muy precisa.

Por otra parte, el proceso de automatización de la detección de cambios es una de las líneas de investigación el más importantes en los últimos años. Se requiere una base de datos del área de interés y una mínima intervención del analista. Lo que lleva a tener que desarrollar tanto los algoritmos de detección, como las herramientas de evaluación. La continuidad y la disponibilidad de las series de datos obtenidos en la misma zona con distintas fechas de adquisición permiten analizar los cambios y prevenir sus consecuencias. La disponibilidad de toda esta información permitirá en un futuro no muy lejano desarrollar herramientas muy útiles para un gestor territorial. Para ello se requerirá un análisis y seguimiento continuo de las áreas de interés. Los estudios de detección de cambios y la motorización de la Tierra requieren datos actualizados y continuos para detectar y estimar los cambios y proponer las soluciones adecuadas. Por esta razón, la automatización de los procesos de detección de cambios representa un área de interés creciente, que en un mundo conectado puede incluso incorporar cada vez más datos de campo obtenidos in situ.

Lista de publicaciones

A.1 Artículos publicados en revistas

- S. A. Azzouzi, A. V. Pantaleoni, and H. A. Bentounes, “Desertification monitoring in Biskra, Algeria, with Landsat imagery by means of supervised classification and change detection methods”, *IEEE Access*, vol. 5, pp. 9065–9072, 2017.
- S. A. Azzouzi, A. V. Pantaleoni, and H. A. Bentounes, “Monitoring desertification in Biskra, Algeria using Landsat 8 and Sentinel-1A images”, *IEEE Access*, vol. 6, pp. 30844–30854, 2018.

A.2 Artículos publicados en conferencias internacionales

- S. A. Azzouzi, A. V. Pantaleoni, and H. A. Bentounes, “A modified approach for change detection using change vector analysis in posterior probability space”, *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL-7/W3, pp. 593–598, 2015.
- S. A. Azzouzi, A. V. Pantaleoni, and H. A. Bentounes, “Enhancement of the double flexible pace search threshold determination for change vector analysis”, *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL-7/W3, pp. 599–603, 2015.

A.3 Artículos publicados en conferencias nacionales

- S. A. Azzouzi, A. V. Pantaleoni, and H. A. Bentounes, “Análisis del cambio de uso del suelo en Argelia mediante la técnica CVA”, *Teledetección: Humedales y Espacios Protegidos. XVI Congreso de la Asociación Española de Teledetección*, pp. 92–95, 2015.

Lista de Figuras

2.1	Avance de desertificación en el Desierto. Fuente: Tim White, n.d.	37
2.2	Imagen óptica tomada por el satélite SPOT 6 en Argel, Argelia con una resolución de 1,5 m. Fuente: Airbus Defence & Space 2012, n.d.	40
2.3	Mosaico de 46 capturas tomadas con el instrumento StripMap del satélite TerraSAR-X en el lago de Constanza, Alemania. Fuente: Airbus Defence & Space, n.d.	42
2.4	Imagen óptica del sensor OLI del satélite Landsat-8 tomada en Aïn Séfra, Argelia el 8 de enero 2018 que representa la nieve en el desierto. Fuente: Landsat 8.	45
3.1	Muestra de zonas de entrenamiento para clasificar la imagen.	57
3.2	Diagrama de flujo de la segmentación y clasificación por objetos.	58
3.3	Muestra de valores de atributos usados en la clasificación por objetos.	60
4.1	Ubicación de la zona de China en el mapa.	71
4.2	El área de estudio de China: imagen de satélite adquirida el 30 de abril de 2000 en (a), e imagen de satélite adquirida el 10 de abril de 2010 en (b).	72
4.3	Mapa de localización del área de estudio en Aïn Defla (Argelia).	73
4.4	Área de estudio en Aïn Defla (Argelia): imagen adquirida el 14 de junio de 2002 en (a), e imagen adquirida el 4 de junio de 2010 en (b).	74
4.5	Diagrama de flujo de la detección de cambio con el método CVA.	76
4.6	Diagrama de flujo del algoritmo <i>Double-Window Flexible Pace Search (DFPS)</i>	78

4.7	Clasificación de la región de China: (a) datos adquiridos el 30 de abril de 2000, y (b) datos adquiridos el 10 de abril de 2010.	83
4.8	Clasificación de la región de Aïn Defla: datos adquiridos el 14 de junio de 2002 en (a), y datos adquiridos el 4 de junio de 2010 en (b).	84
4.9	Mapa de cambio en la sub-área de China.	89
4.10	Mapa de cambio en Argelia. Los píxeles en rojo representan las áreas modificadas.	89
4.11	Discriminación del cambio en la sub-área de China.	90
4.12	Discriminación del cambio en la sub-área de Argelia.	91
5.1	Localización geográfica de la zona de estudio.	101
5.2	Imágenes de Landsat-5 tomadas en los años de estudio y su correspondiente modelo digital de elevación (DEM).	103
5.3	Imágenes Landsat-8 tomadas en 2015 en (a) y 2016 en (c), e imágenes Sentinel-1A tomadas en 2015 en (b) y en 2016 en (d).	104
5.4	Amplitud y dirección del viento del 01-02-2005 al 31-12-2016.	105
5.5	Diagrama de flujo de la detección de desertificación.	107
5.6	Distribución del cambio LULC en los siguientes pares de imágenes: a) utilizando el par 1986-1995, en b) 1995-2007, en c) 2007-2009, en d) 2009-2011 y en e) utilizando el período completo 1986-2011.	122
5.7	Imagen SAR e imagen óptica tomadas en 2015: imagen original VV SAR en (a), imagen VV SAR filtrada con el filtro Lee en (b), imagen VV SAR filtrada con el filtro Frost en (c) y la imagen óptica en (d).	125
5.8	Diagrama de flujo que muestra los diferentes algoritmos para la clasificación de datos ópticos (1) y combina imágenes ópticas y SAR (a-d).	127
5.9	Resultados de la clasificación en datos de 2015 con zoom: utilizando el método (1) en (a), utilizando el método (b) y polarización VV en (b), imagen óptica en (c).	131
5.10	Distribución del LULC entre 16-03-2015 y 02-03-2016.	137

Lista de Tablas

1.1	Métodos de detección de cambios de la categoría Álgebra 1.2.2.1.	11
1.2	Métodos de detección de cambios de la categoría Transformación 1.2.2.2. . .	14
1.3	Métodos de detección de cambios de la categoría Clasificación 1.2.2.3. . . .	17
1.4	Métodos de detección de cambios de la categoría Modelos Avanzados 1.2.2.4.	21
1.5	Métodos de detección de cambios de la categoría SIG 1.2.2.5.	24
1.6	Métodos de detección de cambios de la categoría Análisis Visual 1.2.2.6. . .	24
2.1	Propiedades del satélite Landsat.	44
2.2	Los satélites SPOT y sus características.	47
2.3	Propiedades del satélite Sentinel-1A.	49
3.1	Los tipos de atributos y sus descripciones.	61
3.2	Los parámetros de la matriz de confusión.	64
3.3	Detalle de una matriz de transición entre las fechas t_1 y t_2 en (%).	66
3.4	Los índices de la matriz de transición en (%).	66
4.1	Características de las imágenes del área de estudio en Pekín, China.	70
4.2	Características de las imágenes del área de estudio en Aïn Defla, Argelia. . .	71
4.3	Descripción de las clases usadas.	75
4.4	Resultados de los métodos de clasificación en la zona Pekín (China) en 2010.	81

4.5	Matriz de confusión para la validación de clasificación MLC en el área de China en 2010.	81
4.6	Matriz de confusión para la validación de clasificación MLC en el área de Argelia en 2010.	82
4.7	Resultados de la selección de umbral con el método <i>Double-Window Flexible Pace Search (DFPS)</i> en el área de China.	85
4.8	Resultados de la selección de umbral con el método <i>Double-Window Flexible Pace Search (DFPS)</i> en el área de Argelia.	86
4.9	Matriz de confusión cambio/no-cambio para la zona de China.	87
4.10	Matriz de confusión cambio/no-cambio para la zona de Argelia.	88
4.11	Matriz de transición LULC (%) entre 2000 y 2010 en Pekín, China.	92
4.12	Los índices de cambio LULC entre 2000 y 2010 (%) en Pekín, China.	92
4.13	Matriz de transición LULC (%) entre 2002 y 2010 en Aïn Defla, Argelia.	93
4.14	Los índices de cambio LULC entre 2002 y 2010 (%) en Aïn Defla, Argelia.	93
4.15	Los índices g_p , l_p y n_p obtenidos en China.	94
4.16	Los índices g_p , l_p y n_p obtenidos en Argelia.	94
5.1	Características de las imágenes de Landsat-5.	102
5.2	Características de las imágenes de Landsat-8.	102
5.3	Características de las imágenes Sentinel-1A.	105
5.4	Clases de cobertura del suelo seleccionadas en el estudio.	107
5.5	Matriz de confusión para la validación de la clasificación de 2011 con el clasificador MLC por píxel.	109
5.6	Matriz de confusión para la validación de la clasificación de 2011 con el clasificador SVM por píxel.	109
5.7	Matriz de confusión para la validación de la clasificación de 2011 con el clasificador SVM por objetos.	110
5.8	Matriz de confusión para la validación de la clasificación de 2011 con el clasificador KNN por objetos.	110
5.9	Matriz de confusión para la validación de la clasificación de 2011 con el clasificador PCA por objetos.	111

5.10	Resultados de la selección de umbral con el método <i>Double-Window Flexible Pace Search (DFPS)</i> en el período de estudio de 1986 a 2011.	113
5.11	Matriz de confusión del cambio con el método CVAPS en el período de estudio de 1986 a 2011.	114
5.12	Matriz de confusión del cambio con el método comparación post-clasificación en el período de estudio de 1986 a 2011.	115
5.13	Resultados de la clasificación por objetos usando el método SVM.	116
5.14	Superficie (km ²) de las clases en el área de estudio entre 1986 y 2011.	116
5.15	Matrices de transición LULC (%): en a) de 1986 a 1995, en b) de 1995 a 2007, en c) de 2007 a 2009.	117
5.16	Índices de cambio LULC entre 1986 y 2011 (%).	120
5.17	Relación ganancia a persistencia g_p , relación pérdida a persistencia l_p y relación cambio neto a persistencia n_p en el período de 1986 a 2011.	120
5.18	Resultados de clasificación de los diferentes métodos.	129
5.19	Matriz de confusión de la clasificación en 2015 utilizando el método estándar (1).	130
5.20	Matriz de confusión de la clasificación en 2016 utilizando el método (1).	132
5.21	Matriz de confusión de la clasificación en 2015 utilizando el método (b) y la imagen SAR de polarización VV.	132
5.22	Matriz de confusión de la clasificación en 2016 utilizando el método (b) y la imagen SAR de polarización VV.	133
5.23	Matriz de transición LULC (%) de 2015 a 2016.	134
5.24	Índices de cambio de LULC entre 2015 y 2016 (%).	134
5.25	Índice de pérdida a persistencia l_p , y porcentaje de cambio en el período de 2015 a 2016.	135
5.26	Matriz de confusión usando los datos ópticos y el algoritmo 1.	136
5.27	Matriz de confusión de cambio usando la mejor metodología: técnica (b), algoritmo 3 usando polarización VV sin filtro Speckle.	136

Acrónimos

ANN	Artificial Neural Networks
ARSIS	Agricultural Remote Sensing Information System
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer
AVHRR	Advanced Very High Resolution Radar
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
CERES	Clouds and Earth Radiant Energy System
CK	coeficiente kappa
CNES	Centre National d'Études spatiales
CVA	Change Vector Analysis
CVAPS	Change Vector Analysis in Posterior Probability Space
DEM	Digital Elevation Model
DFPS	Double-Window Flexible Pace Search
DLR	Deutsches Zentrum für Luft- und Raumfahrt (<i>Centro Aeroespacial Alemán</i>)
DOS	Dark Object Subtraction
DV	Dual polarization
EM	Expectation-Maximization algorithm
ENVISAT	Environmental Satellite
EOS	Earth Observing System
ERS-2	European Remote Sensing Satellite Mission 2

ESA	European Space Agency (<i>Agencia Espacial Europea</i>)
ETM+	Enhanced Thematic Mapper Plus
EW	Extra-Wide swath
GRD	Ground Range Detected
GS	Gram-Schmidt
HCDS	Haut Commissariat au Développement de la Steppe
HRG	High-Resolution Geometric
HRS	High-Resolution Stereoscopic
HRV	High-Resolution Visible
HRVIR	High-Resolution Visible and InfraRed
HS	High-Resolution Spotlight
ICVA	Improved Change Vector Analysis
IW	Interferometric Wide swath
JAXA	Japan Aerospace Exploration Agency
KNN	K-Nearest Neighbors
KT	Kauth Thomas
LIBSVM	Library for Support Vector Machines
LiDAR	Light Detection and Ranging
LSMA	Linear Spectral Mixture Analysis
LULC	Land-Use and Land-Cover
MADR	Ministerio de Agricultura y Desarrollo Rural
MAR	Muy Alta Resolución
MCVA	Modified Change Vector Analysis
MDT	Modelo Digital de Terreno
MIR	Mid InfraRed
MISR	Multi-angle Imaging Spectroradiometer
MLC	Maximum Likelihood Classifier
MODIS	Moderate Resolution Imaging Spectroradiometer
MOPITT	Measurements of Pollution in the Troposphere

MSAVI	Modified Soil Adjusted Vegetation Index
MSI	Multi Spectral Instrument
MSS	Multispectral Scanner
NAOMI	New Astrosat Optical Modular Instrument
NASA	National Aeronautics and Space Administration
ND	Niveles Digitales
NDMI	Normalized Difference Moisture Index
NDVI	Normalized Difference Vegetation Index
NIR	Near InfraRed
NOAA	National Oceanic and Atmospheric Administration
OLI	Operational Land Imager
PCA	Principal Component Analysis
PCC	Post Classification Comparison
PG	precisión global
PNDA	Programme National de Développement Agricole
PNUMA	Programa de Naciones Unidas para el Medio Ambiente
PSLV	Polar Satellite Launch Vehicle
RBF	Radial Basis Function
RMSE	Root Mean Square Error
RTB	Ratio of Tree Biomass
SAM	Spectral Angle Mapper
SAR	Synthetic Aperture Radar
SAVI	Soil Adjusted Vegetation Index
SC	ScanSAR
SCVAPS	Supervised Change Vector Analysis in Posterior probability Space
SD	Suelo Descubierta
SERTIT	SERVICE Régional de Traitement d'Image et de Télé-détection
SIG	Sistemas de Información Geográfica
SL	Spotlight

SLC	Scan Line Corrector
SM	StripMap
SNSB	Swedish National Space Board
SPOT	Satellite Pour l'Observation de la Terre
SSTC	Services Fédéraux des Affaires Scientifiques, Techniques et Culturelles
ST	Staring SpotLight
SVM	Support Vector Machine
SWIR	Short Wavelength Infrared
TIE	Un punto en el suelo que es común en dos imágenes. Se usa para el registro de imágenes.
TIRS	Thermal Infrared Sensor
TM	Thematic Mapper
TOPSAR	Terrain Observation with Progressive Scans SAR
UNCCD	United Nations Convention to Combat Desertification
UNOSAT	UNITAR's Operational Satellite Applications Programme
USGS	United States Geological Survey
UTM	Universal Transverse Mercator
VD	Vegetación Densa
VND	Vegetación No Densa
VNIR	Visible Near InfraRed
WGS84	World Geodetic System 1984
WRS-2	Landsat Worldwide Reference System-2
WS	Wide ScanSAR
WV	Wave

Bibliografía

- [1] A. Singh, “Review article digital change detection techniques using remotely-sensed data,” *International Journal of Remote Sensing*, vol. 10, no. 6, pp. 989–1003, 1989.
- [2] N. C. Gautam and G. C. Chennaiah, “Land-use and land-cover mapping and change detection in Tripura using satellite Landsat data,” *International Journal of Remote Sensing*, vol. 6, no. 3-4, pp. 517–528, 1985.
- [3] A. K. Milne and A. L. O’Neill, “Mapping and monitoring land cover in the Willandra lakes World Heritage Region,” *International Journal of Remote Sensing*, vol. 11, no. 11, pp. 2035–2049, 1990.
- [4] T. Fung, “Land use and land cover change detection with Landsat MSS and SPOT HRV data in Hong Kong,” *Geocarto International*, vol. 7, no. 3, pp. 33–40, 1992.
- [5] B. Ram and A. S. Kolarkar, “Remote sensing application in monitoring land-use changes in arid Rajasthan,” *International Journal of Remote Sensing*, vol. 14, no. 17, pp. 3191–3200, 1993.
- [6] K. Green, D. Kempka, and L. Lackey, “Using remote sensing to detect and monitor land-cover and land-use change,” *Photogrammetric Engineering & Remote Sensing*, vol. 60, no. 3, pp. 331–337, 1994.
- [7] B. B. Salem, A. El-Cibahy, and M. El-Raey, “Detection of land cover classes in agro-ecosystems of Northern Egypt by remote sensing,” *International Journal of Remote Sensing*, vol. 16, no. 14, pp. 2581–2594, 1995.
- [8] M. Dimiyati, K. Mizuno, S. Kobayashi, and T. Kitamura, “An analysis of land use/cover change in Indonesia,” *International Journal of Remote Sensing*, vol. 17, no. 5, pp. 931–944, 1996.

- [9] L. Bruzzone and S. B. Serpico, “Detection of changes in remotely-sensed images by the selective use of multi-spectral information,” *International Journal of Remote Sensing*, vol. 18, no. 18, pp. 3883–3888, 1997.
- [10] S. Sommer, J. Hill, and J. Mégier, “The potential of remote sensing for monitoring rural land use changes and their effects on soil conditions,” *Agriculture, Ecosystems & Environment*, vol. 67, no. 2, pp. 197–209, 1998.
- [11] J. T. Morisette, S. Khorram, and T. Mace, “Land-cover change detection enhanced with generalized linear models,” *International Journal of Remote Sensing*, vol. 20, no. 14, pp. 2703–2721, 1999.
- [12] X. Zhan, R. Defries, J. R. G. Townshend, C. Dimiceli, M. Hansen, C. Huang, and R. Sohlberg, “The 250 m global land cover change product from the moderate resolution imaging spectroradiometer of NASA’s Earth Observing System,” *International Journal of Remote Sensing*, vol. 21, no. 6-7, pp. 1433–1460, 2000.
- [13] R. K. Kaufmann and K. C. Seto, “Change detection, accuracy, and bias in a sequential analysis of Landsat imagery in the Pearl River Delta, China: econometric techniques,” *Agriculture, Ecosystems & Environment*, vol. 85, no. 1, pp. 95–105, 2001, predicting Land-Use Change.
- [14] Q. Weng, “Land use change analysis in the Zhujiang Delta of China using satellite remote sensing, GIS and stochastic modelling,” *Journal of Environmental Management*, vol. 64, no. 3, pp. 273–284, 2002.
- [15] P. Manavalan, K. Kesavasamy, and S. Adiga, “Irrigated crops monitoring through seasons using digital change detection analysis of IRS-LISS 2 data,” *International Journal of Remote Sensing*, vol. 16, no. 4, pp. 633–640, 1995.
- [16] D. M. Gupta and M. K. Munshi, “Land use and forestry studies of Himachal Pradesh,” *International Journal of Remote Sensing*, vol. 6, no. 3-4, pp. 535–539, 1985.
- [17] J. E. Vogelmann, “Detection of forest change in the Green Mountains of Vermont using multispectral scanner data,” *International Journal of Remote Sensing*, vol. 9, no. 7, pp. 1187–1200, 1988.
- [18] S. E. Franklin and B. Wilson, “Vegetation mapping and change detection using SPOT MLA and Landsat imagery in Kluane National Park,” *Canadian Journal of Remote Sensing*, vol. 17, no. 1, pp. 2–17, 1991.

-
- [19] S. A. Sader and J. C. Winne, "RGB-NDVI colour composites for visualizing forest change dynamics," *International Journal of Remote Sensing*, vol. 13, no. 16, pp. 3055–3067, 1992.
- [20] M. A. Alwashe and A. Y. Bokhari, "Monitoring vegetation changes in Al Madinah, Saudi Arabia, using Thematic Mapper data," *International Journal of Remote Sensing*, vol. 14, no. 2, pp. 191–197, 1993.
- [21] P. R. Coppin and M. E. Bauer, "Processing of multitemporal Landsat TM imagery to optimize extraction of forest cover change features," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, no. 4, pp. 918–927, 1994.
- [22] J. Mishra, R. Aarathi, and M. Joshi, "Remote sensing quantification and change detection of natural resources over Delhi," *Atmospheric Environment*, vol. 28, no. 19, pp. 3131–3137, 1994.
- [23] P. R. Coppin and M. E. Bauer, "The potential contribution of pixel-based canopy change information to stand-based forest management in the Northern U.S.," *Journal of Environmental Management*, vol. 44, no. 1, pp. 69–82, 1995.
- [24] D. A. Mouat and J. Lancaster, "Use of remote sensing and GIS to identify vegetation change in the upper San Pedro River watershed, Arizona," *Geocarto International*, vol. 11, no. 2, pp. 55–67, 1996.
- [25] M. J. Islam, M. S. Alam, and K. M. Elahi, "Remote sensing for change detection in the Sunderbands, Bangladesh," *Geocarto International*, vol. 12, no. 3, pp. 91–100, 1997.
- [26] A. P. Jano, R. L. Jefferies, and R. F. Rockwell, "The detection of vegetational change by multitemporal analysis of Landsat data: the effects of goose foraging," *Journal of Ecology*, vol. 86, no. 1, pp. 93–99, 1998.
- [27] A. T. Salami, O. Ekanade, and R. O. Oyinloye, "Detection of forest reserve incursion in south-western Nigeria from a combination of multi-date aerial photographs and high resolution satellite imagery," *International Journal of Remote Sensing*, vol. 20, no. 8, pp. 1487–1497, 1999.
- [28] C. E. Woodcock, S. A. Macomber, M. Pax-Lenney, and W. B. Cohen, "Monitoring large areas for forest change using Landsat: Generalization across space, time and Landsat sensors," *Remote Sensing of Environment*, vol. 78, no. 1, pp. 194–203, 2001.

- [29] D. Lu, P. Mausel, E. Brondízio, and E. Moran, “Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin,” *Forest Ecology and Management*, vol. 198, no. 1, pp. 149–167, 2004.
- [30] R. F. Nelson, “Detecting forest canopy change due to insect activity using Landsat MSS,” *Photogrammetric Engineering & Remote Sensing*, vol. 49, no. 9, pp. 1303–1314, 1983.
- [31] D. G. Leckie, “Factors affecting defoliation assessment using airborne multispectral scanner data,” *Photogrammetric Engineering & Remote Sensing*, vol. 53, no. 12, pp. 1665–1674, 1987.
- [32] J. E. Vogelmann and B. N. Rock, “Use of thematic mapper data for the detection of forest damage caused by the pear thrips,” *Remote Sensing of Environment*, vol. 30, no. 3, pp. 217–225, 1989.
- [33] K. P. Price, D. A. Pyke, and L. Mendes, “Shrub dieback in a semiarid ecosystem: the integration of remote sensing and GIS for detecting vegetation change,” *Photogrammetric Engineering & Remote Sensing*, vol. 58, no. 4, pp. 455–463, 1992.
- [34] J. B. Collins and C. E. Woodcock, “Change detection using the Gramm-Schmidt transformation applied to mapping forest mortality,” *Remote Sensing of Environment*, vol. 50, no. 3, pp. 267–279, 1994.
- [35] S. A. Macomber and C. E. Woodcock, “Mapping and monitoring conifer mortality using remote sensing in the Lake Tahoe Basin,” *Remote Sensing of Environment*, vol. 50, no. 3, pp. 255–266, 1994.
- [36] S. Gopal and C. Woodcock, “Remote sensing of forest change using artificial neural networks,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 34, no. 2, pp. 398–404, 1996.
- [37] O. Rigina, A. Baklanov, O. Hagner, and H. Olsson, “Monitoring of forest damage in the Kola Peninsula, Northern Russia due to smelting industry,” *Science of The Total Environment*, vol. 229, no. 3, pp. 147–163, 1999.
- [38] J. A. Richards, “Thematic mapping from multitemporal image data using the principal components transformation,” *Remote Sensing of Environment*, vol. 16, no. 1, pp. 35–46, 1984.
- [39] R. Nelson, N. Horning, and T. A. Stone, “Determining the rate of forest conversion in Mato Grosso, Brazil, using Landsat MSS and AVHRR data,” *International Journal of Remote Sensing*, vol. 8, no. 12, pp. 1767–1784, 1987.

-
- [40] R. M. Lucas, M. Honzák, G. M. Foody, P. J. Curran, and C. Corves, “Characterizing tropical secondary forests using multi-temporal Landsat sensor imagery,” *International Journal of Remote Sensing*, vol. 14, no. 16, pp. 3061–3067, 1993.
- [41] R. M. Lucas, M. Honzák, P. J. Curran, G. M. Foody, R. Milne, T. Brown, and S. Amaral, “Mapping the regional extent of tropical forest regeneration stages in the Brazilian Legal Amazon using NOAA AVHRR data,” *International Journal of Remote Sensing*, vol. 21, no. 15, pp. 2855–2881, 2000.
- [42] R. M. Lucas, M. Honzák, I. D. Amaral, P. J. Curran, and G. M. Foody, “Forest regeneration on abandoned clearances in central Amazonia,” *International Journal of Remote Sensing*, vol. 23, no. 5, pp. 965–988, 2002.
- [43] A. Marini and M. Talbi, *Desertification and risk analysis using high and medium resolution satellite data*. Netherlands: Springer Netherlands, 2009.
- [44] D. Y. Xu, X. W. Kang, D. F. Zhuang, and J. J. Pan, “Multi-scale quantitative assessment of the relative roles of climate change and human activities in desertification - a case study of the Ordos Plateau, China,” *Journal of Arid Environments*, vol. 74, no. 4, pp. 498–507, 2010.
- [45] A. Kannan, *Global environmental governance and desertification: a study of Gulf Cooperation Council Countries*. Delhi, Inde: New Delhi: The Concept Publishers, 2012.
- [46] J. Li, L. Zhao, B. Xu, X. Yang, Y. Jin, T. Gao, H. Yu, F. Zhao, H. Ma, and Z. Qin, “Spatiotemporal variations in grassland desertification based on Landsat images and spectral mixture analysis in Yanchi County of Ningxia, China,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 11, pp. 4393–4402, 2014.
- [47] Y. Wang and X. Yan, “Climate change induced by Southern Hemisphere desertification,” *Physics and Chemistry of the Earth, Parts A/B/C*, vol. 102, no. Supplement C, pp. 40–47, 2017.
- [48] S. A. Azzouzi, A. Vidal-Pantaleoni, and H. A. Bentounes, “Desertification monitoring in Biskra, Algeria, with Landsat imagery by means of supervised classification and change detection methods,” *IEEE Access*, vol. 5, pp. 9065–9072, 2017.
- [49] S. Singh, K. D. Sharma, N. Singh, and D. N. Bohra, “Temporal change detection in uplands and gullied areas through satellite remote-sensing,” *Annals of Arid Zone*, vol. 29, no. 3, pp. 171–177, 1990.

- [50] M. E. Jakubauskas, K. P. Lulla, and P. W. Mausel, “Assessment of vegetation change in a fire-altered forest landscape,” *Photogrammetric Engineering & Remote Sensing*, vol. 56, no. 3, pp. 371–377, 1990.
- [51] P. R. Siljestrom and A. M. Lopez, “Monitoring burnt areas by principal components analysis of multi-temporal TM data,” *International Journal of Remote Sensing*, vol. 16, no. 9, pp. 1577–1587, 1995.
- [52] D. O. Fuller, “Satellite remote sensing of biomass burning with optical and thermal sensors,” *Progress in Physical Geography*, vol. 24, no. 4, pp. 543–561, 2000.
- [53] L. L. Bourgeau-Chavez, E. S. Kasischke, S. Brunzell, J. P. Mudd, and M. Tukman, “Mapping fire scars in global boreal forests using imaging radar data,” *International Journal of Remote Sensing*, vol. 23, no. 20, pp. 4211–4234, 2002.
- [54] A. Garcia-Martin, F. Perez-Cabello, J. de la Riva Fernandez, and R. M. Lloveria, “Estimation of crown biomass of pinus spp. from Landsat TM and its effect on burn severity in a spanish fire scar,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 1, no. 4, pp. 254–265, 2008.
- [55] X. Zhang, S. Kondragunta, and B. Quayle, “Estimation of biomass burned areas using multiple-satellite-observed active fires,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 11, pp. 4469–4482, 2011.
- [56] A. Leboeuf and R. A. Fournier, “A multisensor multiresolution method for mapping vegetation status, surficial deposits, and historical fires over very large areas in Northern Boreal Forests of Quebec, Canada,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 11, pp. 5199–5211, 2015.
- [57] P. Imperatore, R. Azar, F. Cal, D. Stroppiana, P. A. Brivio, R. Lanari, and A. Pepe, “Effect of the vegetation fire on backscattering: An investigation based on Sentinel-1 observations,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 10, pp. 4478–4492, 2017.
- [58] P. J. Howarth and G. M. Wickware, “Procedures for change detection using Landsat digital data,” *International Journal of Remote Sensing*, vol. 2, no. 3, pp. 277–291, 1981.
- [59] H. Schmidt and C. Glaesser, “Multitemporal analysis of satellite data and their use in the monitoring of the environmental impacts of open cast lignite mining areas in Eastern Germany,” *International Journal of Remote Sensing*, vol. 19, no. 12, pp. 2245–2260, 1998.

-
- [60] J. S. Hu and T. M. Su, “Robust environmental change detection using PTZ camera via spatial-temporal probabilistic modeling,” *IEEE/ASME Transactions on Mechatronics*, vol. 12, no. 3, pp. 339–344, 2007.
- [61] B. Liang and Q. Weng, “Assessing urban environmental quality change of Indianapolis, United States, by the remote sensing and GIS integration,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 4, no. 1, pp. 43–55, 2011.
- [62] E. Asbridge and R. M. Lucas, “Mangrove response to environmental change in Kakadu national park,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 12, pp. 5612–5620, 2016.
- [63] D. Zheng, D. O. Wallin, and Z. Hao, “Rates and patterns of landscape change between 1972 and 1988 in the Changbai mountain area of China and North Korea,” *Landscape Ecology*, vol. 12, no. 4, pp. 241–254, 1997.
- [64] W. G. Kepner, C. J. Watts, C. M. Edmonds, J. K. Maingi, S. E. Marsh, and G. Luna, “A landscape approach for detecting and evaluating change in a semi-arid environment,” *Environmental Monitoring and Assessment*, vol. 64, no. 1, pp. 179–195, 2000.
- [65] A. Amerasekera, “The changing design landscape,” *IEEE Design Test of Computers*, vol. 25, no. 4, pp. 333–333, 2008.
- [66] J. E. Vogelmann, J. R. Kost, B. Tolk, S. Howard, K. Short, X. Chen, C. Huang, K. Pabst, and M. G. Rollins, “Monitoring landscape change for LANDFIRE using multi-temporal satellite imagery and ancillary data,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 4, no. 2, pp. 252–264, 2011.
- [67] J. N. Hird, G. Castilla, G. J. McDermid, and I. T. Bueno, “A simple transformation for visualizing non-seasonal landscape change from dense time series of satellite data,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 8, pp. 3372–3383, 2016.
- [68] H. Kimura and Y. Yamaguchi, “Detection of landslide areas using satellite radar interferometry,” *Photogrammetric Engineering & Remote Sensing*, vol. 66, no. 3, pp. 337–344, 2000.
- [69] N. A. Quarmby and J. L. Cushnie, “Monitoring urban land cover changes at the urban fringe from SPOT HRV imagery in south-east England,” *International Journal of Remote Sensing*, vol. 10, no. 6, pp. 953–963, 1989.

- [70] A. G. Yeh and X. Li, “An integrated remote sensing and GIS approach in the monitoring and evaluation of rapid urban growth for sustainable development in the Pearl River Delta, China,” *International Planning Studies*, vol. 2, no. 2, pp. 193–210, 1997.
- [71] N. Haala, C. Brenner, and K. H. Anders, “3D Urban GIS from Laser Altimeter and 2D Map Data,” in *ISPRS Commission III Symposium on Object Recognition and Scene Classification from Multispectral and Multisensor Pixels*, 1998, pp. 339–346.
- [72] M. K. Ridd and J. Liu, “A comparison of four algorithms for change detection in an urban environment,” *Remote Sensing of Environment*, vol. 63, no. 2, pp. 95–100, 1998.
- [73] J. Tang, L. Wang, and Z. Yao, “Spatio-temporal urban landscape change analysis using the Markov chain model and a modified genetic algorithm,” *International Journal of Remote Sensing*, vol. 28, no. 15, pp. 3255–3271, 2007.
- [74] P. Du, S. Liu, P. Gamba, K. Tan, and J. Xia, “Fusion of difference images for change detection over urban areas,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 5, no. 4, pp. 1076–1086, 2012.
- [75] O. Yousif and Y. Ban, “Improving SAR-based urban change detection by combining MAP-MRF classifier and nonlocal means similarity weights,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 10, pp. 4288–4300, 2014.
- [76] M. Che, P. Du, and P. Gamba, “2- and 3-D urban change detection with Quad-PolSAR data,” *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 1, pp. 68–72, 2018.
- [77] E. J. Christensen, J. R. Jensen, E. W. Ramsey, and H. E. Jr. Mackey, “Aircraft MSS data registration and vegetation classification for wetland change detection,” *International Journal of Remote Sensing*, vol. 9, no. 1, pp. 23–38, 1988.
- [78] J. R. Jensen, D. J. Cowen, J. D. Althausen, S. Narumalani, and O. Weatherbee, “An evaluation of the Coastwatch change detection protocol in South Carolina,” *Photogrammetric Engineering & Remote Sensing*, vol. 59, no. 6, pp. 1039–1046, 1993.
- [79] K. O. Pope, J. M. Rey-Benayas, and J. F. Paris, “Radar remote sensing of forest and wetland ecosystems in the Central American tropics,” *Remote Sensing of Environment*, vol. 48, no. 2, pp. 205–219, 1994.

-
- [80] C. H. D. Magadza, “Climate change: some likely multiple impacts in Southern Africa,” *Food Policy*, vol. 19, no. 2, pp. 165–191, 1994.
- [81] S. P. S. Kushwaha, R. S. Dwivedi, and B. R. M. Rao, “Evaluation of various digital image processing techniques for detection of coastal wetlands using ERS-1 SAR data,” *International Journal of Remote Sensing*, vol. 21, no. 3, pp. 565–579, 2000.
- [82] J. Evans and R. Geerken, “Discrimination between climate and human-induced dryland degradation,” *Journal of Arid Environments*, vol. 57, no. 4, pp. 535–554, 2004.
- [83] S. Tripathi, V. V. Srinivas, and R. S. Nanjundiah, “Downscaling of precipitation for climate change scenarios: A support vector machine approach,” *Journal of Hydrology*, vol. 330, no. 3, pp. 621–640, 2006.
- [84] S. Li and Y. Xie, “Investigating coupled impacts of climate change and socioeconomic transformation on desertification by using multitemporal Landsat images: A case study in central Xilingol, China,” *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 5, pp. 1244–1248, 2013.
- [85] A. Elouissi, M. Habi, B. Benaricha, and S. A. Boualem, “Climate change impact on rainfall spatio-temporal variability (Macta watershed case, Algeria),” *Arabian Journal of Geosciences*, vol. 10, no. 22, p. 496, 2017.
- [86] A. J. Peters, E. A. Walter-Shea, L. Ji, A. Viña, M. Hayes, and M. D. Svoboda, “Drought monitoring with NDVI-based standardized vegetation index,” *Photogrammetric Engineering & Remote Sensing*, vol. 68, no. 1, pp. 71–75, 2002.
- [87] C. Zhou, J. Luo, C. Yang, B. Li, and S. Wang, “Flood monitoring using multi-temporal AVHRR and RADARSAT imagery,” *Photogrammetric Engineering & Remote Sensing*, vol. 66, no. 5, pp. 633–638, 2000.
- [88] J. L. Michalek, T. W. Wagner, J. J. Luczkovich, and R. W. Stoffle, “Multispectral change vector analysis for monitoring coastal marine environments,” *Photogrammetric Engineering & Remote Sensing*, vol. 59, no. 3, pp. 381–384, 1993.
- [89] R. V. Engeset, J. Kohler, K. Melvold, and B. Lundén, “Change detection and monitoring of glacier mass balance and facies using ERS SAR winter images over Svalbard,” *International Journal of Remote Sensing*, vol. 23, no. 10, pp. 2023–2050, 2002.
- [90] D. A. Mouat, G. G. Mahin, and J. Lancaster, “Remote sensing techniques in the analysis of change detection,” *Geocarto International*, vol. 8, no. 2, pp. 39–50, 1993.

- [91] J. R. Jensen, *Introductory digital image processing: a remote sensing perspective*, 2nd ed. Prentice Hall, 1995.
- [92] P. R. Coppin and M. E. Bauer, “Digital change detection in forest ecosystems with remote sensing imagery,” *Remote Sensing Reviews*, vol. 13, no. 3-4, pp. 207–234, 1996.
- [93] D. Yuan and C. Elvidge, “NALC land cover change detection pilot study: Washington D.C. area experiments,” *Remote Sensing of Environment*, vol. 66, no. 2, pp. 166–178, 1998.
- [94] S. B. Serpico and L. Bruzzone, *Information processing for Remote Sensing*. World Scientific, 1999, ch. Change Detection, pp. 319–336.
- [95] J. B. Adams, D. E. Sabol, V. Kapos, R. A. Filho, D. A. Roberts, M. O. Smith, and A. R. Gillespie, “Classification of multispectral images based on fractions of endmembers: Application to land-cover change in the Brazilian Amazon,” *Remote Sensing of Environment*, vol. 52, no. 2, pp. 137–154, 1995.
- [96] G. Metternicht, “Change detection assessment using fuzzy sets and remotely sensed data: an application of topographic map revision,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 54, no. 4, pp. 221–233, 1999.
- [97] C. Petit and E. Lambin, “Integration of multi-source remote sensing data for land cover change detection,” *International Journal of Geographical Information Science*, vol. 15, no. 8, pp. 785–803, 2001.
- [98] W. A. Malila, “Change vector analysis: An approach for detecting forest changes with Landsat,” in *Proceedings of Sixth Annual Symposium on Machine Processing of Remotely Sensed Data and Soil Information Systems and Remote Sensing and Soil Survey*, 1980, pp. 326–335.
- [99] J. Chen, P. Gong, C. He, R. Pu, and P. Shi, “Land-use/land-cover change detection using improved change-vector analysis,” *Photogrammetric Engineering & Remote Sensing*, vol. 69, no. 4, pp. 369–379, 2003.
- [100] K. Nackaerts, K. Vaesen, B. Muys, and P. Coppin, “Comparative performance of a modified change vector analysis in forest change detection,” *International Journal of Remote Sensing*, vol. 26, pp. 839–852, 2005.
- [101] J. Chen, X. Chen, X. Cui, and J. Chen, “Change vector analysis in posterior probability space: A new method for land cover change detection,” *IEEE Geoscience and Remote Sensing Letters*, vol. 8, no. 2, pp. 317–321, 2011.

-
- [102] D. Lu, P. Mausel, E. B. E., and Moran, “Change detection techniques,” *International Journal of Remote Sensing*, vol. 25, no. 12, pp. 2365–2401, 2004.
- [103] R. D. Macleod and R. G. Congalton, “A quantitative comparison of change-detection algorithms for monitoring eelgrass from remotely sensed data,” *Photogrammetric Engineering & Remote Sensing*, vol. 64, no. 3, pp. 207–216, 1998.
- [104] E. F. Lambin and A. H. Strahlers, “Change-vector analysis in multitemporal space: A tool to detect and categorize land-cover change processes using high temporal-resolution satellite data,” *Remote Sensing of Environment*, vol. 48, no. 2, pp. 231–244, 1994.
- [105] J. R. G. Townshend, C. O. Justice, C. Gurney, and J. McManus, “The impact of misregistration on change detection,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, no. 5, pp. 1054–1060, 1992.
- [106] E. F. Vermote, D. Tanre, J. L. Deuze, M. Herman, and J. J. Morcette, “Second simulation of the satellite signal in the solar spectrum, 6S: an overview,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 35, no. 3, pp. 675–686, 1997.
- [107] S.-H. Park, H.-S. Jung, J. Choi, and S. Jeon, “A quantitative method to evaluate the performance of topographic correction models used to improve land cover identification,” *Advances in Space Research*, vol. 60, no. 7, pp. 1488–1503, 2017.
- [108] M. J. Canty, *Image analysis, classification, and change detection in Remote Sensing: with algorithms for ENVI/IDL*, 2nd ed. Boca Raton, FL, USA: CRC Press, Inc., 2009.
- [109] G. Angelici, N. Brynt, and S. Friendman, “Techniques for land use change detection using Landsat imagery,” in *Proceedings of the 43rd Annual Meeting of the American Society of Photogrammetry and Joint Symposium on Land Data Systems, Falls Church, VA, USA*, 1977, pp. 217–228.
- [110] J. R. Jensen and D. L. Toll, “Detecting residential land-use development at the urban fringe,” *Photogrammetric Engineering & Remote Sensing*, vol. 48, no. 4, pp. 629–643, 1982.
- [111] J. P. S. Chavez and D. J. Mackinnon, “Automatic detection of vegetation changes in the Southwestern United States using remotely sensed images,” *Photogrammetric Engineering & Remote Sensing*, vol. 60, no. 5, pp. 571–583, 1994.

- [112] P. G. Pilon, P. J. Howarth, R. A. Bullock, and P. O. Adeniyi, “An enhanced classification approach to change detection in semi-arid environments,” *Photogrammetric Engineering & Remote Sensing*, vol. 54, no. 12, pp. 1709–1716, 1988.
- [113] D. A. Stow, “Reducing the effects of misregistration on pixel-level change detection,” *International Journal of Remote Sensing*, vol. 20, no. 12, pp. 2477–2483, 1999.
- [114] A. Prakash and R. P. Gupta, “Land-use mapping and change detection in a coal mining area - a case study in the Jharia coalfield, India,” *International Journal of Remote Sensing*, vol. 19, no. 3, pp. 391–410, 1998.
- [115] J. G. Lyon, D. Yuan, R. S. Lunetta, and C. D. Elvidge, “A change detection experiment using vegetation indices,” *Photogrammetric Engineering & Remote Sensing*, vol. 64, no. 2, pp. 143–150, 1998.
- [116] T. L. Sohl, “Change analysis in the United Arab Emirates: An investigation of techniques,” *Photogrammetric Engineering & Remote Sensing*, vol. 65, no. 4, pp. 475–484, 1999.
- [117] D. J. Hayes and S. A. Sader, “Comparison of change detection techniques for monitoring tropical forest clearing and vegetation regrowth in a time series,” *Photogrammetric Engineering & Remote Sensing*, vol. 67, no. 9, pp. 1067–1075, 2001.
- [118] B. N. Subudhi, S. Ghosh, S. C. K. Shiu, and A. Ghosh, “Statistical feature bag based background subtraction for local change detection,” *Information Sciences*, vol. 366, pp. 31–47, 2016.
- [119] V. Arun and G. Sreelekha, “Sample-based integrated background subtraction and shadow detection,” *IPSN Transactions on Computer Vision and Applications*, vol. 9, no. 1, p. 25, 2017.
- [120] D. M. Muchoney and B. N. Haack, “Change detection for monitoring forest defoliation,” *Photogrammetric Engineering & Remote Sensing*, vol. 60, no. 10, pp. 1243–1251, 1994.
- [121] R. D. Johnson and E. S. Kasischke, “Change vector analysis: A technique for the multispectral monitoring of land cover and condition,” *International Journal of Remote Sensing*, vol. 19, no. 3, pp. 411–426, 1998.
- [122] T. R. Allen and J. A. Kupfer, “Application of spherical statistics to change vector analysis of Landsat data: Southern Appalachian Spruce-fir forests,” *Remote Sensing of Environment*, vol. 74, no. 3, pp. 482–493, 2000.

- [123] K. Arnon, Q. Zhihao, W. Bo, P. Natalya, and Y. Feng, “Spatio-temporal dynamics of land-use and land-cover in the Mu Us Sandy Land, China, using the change vector analysis technique,” *Remote Sensing*, vol. 6, no. 10, pp. 9316–9339, 2014.
- [124] A. A. M. Salih, E.-T. Ganawa, and A. A. Elmahl, “Spectral mixture analysis (SMA) and change vector analysis (CVA) methods for monitoring and mapping land degradation/desertification in arid and semiarid areas (Sudan), using Landsat imagery,” *The Egyptian Journal of Remote Sensing and Space Science*, vol. 20, pp. S21–S29, 2017.
- [125] V. Iosif, “Applying the change vector analysis technique to assess the desertification risk in the south-west of Romania in the period 1984-2011,” *Environmental Monitoring and Assessment*, vol. 189, no. 10, p. 524, 2017.
- [126] T. Fung and E. LeDrew, “Application of principal components analysis to change detection,” *Photogrammetric Engineering & Remote Sensing*, vol. 53, no. 12, pp. 1649–1658, 1987.
- [127] T. Fung, “An assessment of TM imagery for land cover change detection,” in *12th Canadian Symposium on Remote Sensing Geoscience and Remote Sensing Symposium*, 1990, pp. 681–684.
- [128] S. Baronti, R. Carla, S. Sigismondi, and L. Alparone, “Principal component analysis for change detection on polarimetric multitemporal SAR data,” in *Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation., International*, 1994, pp. 2152–2154.
- [129] S. K. Guirguis, H. M. Hassan, M. E. El-Raey, and M. M. A. Hussain, “Technical note multi-temporal change of Lake Brullus, Egypt, from 1983 to 1991,” *International Journal of Remote Sensing*, vol. 17, no. 15, pp. 2915–2921, 1996.
- [130] A. Singh and A. Harrison, “Standardized principal components,” *International Journal of Remote Sensing*, vol. 6, no. 6, pp. 883–896, 1985.
- [131] L. Eklundh and A. Singh, “A comparative analysis of standardised and unstandardised principal components analysis in remote sensing,” *International Journal of Remote Sensing*, vol. 14, no. 7, pp. 1359–1370, 1993.
- [132] Z. Anna, B. Gabriele, and K. Arnon, “Monitoring desertification by remote sensing using the Tasselled Cap transform for long-term change detection,” *Natural Hazards*, vol. 83, no. 1, pp. 223–237, 2016.

- [133] F. Sunar, “An analysis of changes in a multi-date data set: A case study in the Ikitelli area, Istanbul, Turkey,” *International Journal of Remote Sensing*, vol. 19, no. 2, pp. 225–235, 1998.
- [134] J. B. Collins and C. E. Woodcock, “An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data,” *Remote Sensing of Environment*, vol. 56, no. 1, pp. 66–77, 1996.
- [135] J. Rogan and S. R. Yool, “Mapping fire-induced vegetation depletion in the Peloncillo Mountains, Arizona and New Mexico,” *International Journal of Remote Sensing*, vol. 22, no. 16, pp. 3101–3121, 2001.
- [136] P. Gong, “Change detection using principal component analysis and fuzzy set theory,” *Canadian Journal of Remote Sensing*, vol. 19, no. 1, pp. 22–29, 1993.
- [137] K. Yones, K. Farshad, E. Soheila, E. C. Brevik, and A. P. Jacqueline, “Assessment and monitoring of soil degradation during land use change using multivariate analysis,” *Land Degradation & Development*, vol. 28, no. 1, pp. 128–141, 2017.
- [138] T. Han, M. A. Wulder, J. C. White, N. C. Coops, M. F. Alvarez, and C. Butson, “An efficient protocol to process Landsat images for change detection with Tasselled Cap Transformation,” *IEEE Geoscience and Remote Sensing Letters*, vol. 4, no. 1, pp. 147–151, 2007.
- [139] R. A. S. Rosa, D. Fernandes, J. B. Nogueira, and C. Wimmer, “Automatic change detection in multitemporal X- and P-band SAR images using Gram-Schmidt process,” in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015, pp. 2797–2800.
- [140] A. Shi, D. Q. Huynh, F. C. Huang, S. H. Shen, W. P. Lu, and Z. L. Ma, “Unsupervised change detection based on robust chi-squared transform for bitemporal remotely sensed images,” *International Journal of Remote Sensing*, vol. 35, no. 21, pp. 7555–7566, 2014.
- [141] C. Zhang, G. Li, and W. Cui, “High resolution remote sensing image change detection based on law of cosines with box-whisker plot,” in *2017 International Workshop on Remote Sensing with Intelligent Processing (RSIP)*, 2017, pp. 1–9.
- [142] X. Li and A. G. O. Yeh, “Principal component analysis of stacked multi-temporal images for the monitoring of rapid urban expansion in the Pearl River Delta,” *International Journal of Remote Sensing*, vol. 19, no. 8, pp. 1501–1518, 1998.

-
- [143] C. S. Silapaswan, D. L. Verbyla, and A. D. McGuire, “Land cover change on the Seward Peninsula: The use of remote sensing to evaluate the potential influences of climate warming on historical vegetation dynamics,” *Canadian Journal of Remote Sensing*, vol. 27, no. 5, pp. 542–554, 2001.
- [144] C. Petit, T. Scudder, and E. Lambin, “Quantifying processes of land-cover change by remote sensing: Resettlement and rapid land-cover changes in south-eastern Zambia,” *International Journal of Remote Sensing*, vol. 22, no. 17, pp. 3435–3456, 2001.
- [145] G. M. Foody, “Monitoring the magnitude of landcover change around the southern limits of the Sahara,” *Photogrammetric Engineering & Remote Sensing*, vol. 67, no. 7, pp. 841–847, 2001.
- [146] E. H. Wilson and S. A. Sader, “Detection of forest harvest type using multiple dates of Landsat TM imagery,” *Remote Sensing of Environment*, vol. 80, no. 3, pp. 385–396, 2002.
- [147] X. L. Dai and S. Khorram, “Remotely sensed change detection based on artificial neural networks,” pp. 1187–1194, 1999.
- [148] X. Liu and J. G. Lathrop, “Urban change detection based on an artificial neural network,” *International Journal of Remote Sensing*, vol. 23, no. 12, pp. 2513–2518, 2002.
- [149] J. F. Mas, “Monitoring land-cover changes: A comparison of change detection techniques,” *International Journal of Remote Sensing*, vol. 20, no. 1, pp. 139–152, 1999.
- [150] R. Peiman, “Pre-classification and post-classification change-detection techniques to monitor land-cover and land-use change using multi-temporal Landsat imagery: a case study on Pisa Province in Italy,” *International Journal of Remote Sensing*, vol. 32, no. 15, pp. 4365–4381, 2011.
- [151] M. M. El-Hattab, “Applying post classification change detection technique to monitor an Egyptian coastal zone (Abu Qir Bay),” *The Egyptian Journal of Remote Sensing and Space Science*, vol. 19, no. 1, pp. 23–36, 2016.
- [152] A. M. Lal and S. M. Anuncia, “Semi-supervised change detection approach combining sparse fusion and constrained k means for multi-temporal remote sensing images,” *The Egyptian Journal of Remote Sensing and Space Science*, vol. 18, no. 2, pp. 279–288, 2015.

- [153] Z. Anna and B. Gabriele, “A combined change detection procedure to study desertification using opensource tools,” *Open Geospatial Data, Software and Standards*, vol. 2, no. 1, p. 10, 2017.
- [154] Y. Bazi, F. Melgani, L. Bruzzone, and G. Vernazza, “A genetic expectation-maximization method for unsupervised change detection in multitemporal SAR imagery,” *International Journal of Remote Sensing*, vol. 30, no. 24, pp. 6591–6610, 2009.
- [155] J. Monaco, P. Raess, R. Chawla, A. Bagg, M. Weiss, J. Choi, and A. Madabhushi, “Image segmentation with implicit color standardization using cascaded EM: Detection of myelodysplastic syndromes,” in *2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*, 2012, pp. 740–743.
- [156] M. Hao, W. Shi, H. Zhang, and C. Li, “Unsupervised change detection with expectation-maximization-based level set,” *IEEE Geoscience and Remote Sensing Letters*, vol. 11, no. 1, pp. 210–214, 2014.
- [157] T. Hame, I. Heiler, and J. S. M. Ayanz, “An unsupervised change detection and recognition system for forestry,” *International Journal of Remote Sensing*, vol. 19, no. 6, pp. 1079–1099, 1998.
- [158] M. Volpi, D. Tuia, G. Camps-Valls, and M. Kanevski, “Unsupervised change detection with kernels,” *IEEE Geoscience and Remote Sensing Letters*, vol. 9, no. 6, pp. 1026–1030, 2012.
- [159] L. Qingjie, L. Lining, and W. Yunhong, “Unsupervised change detection for multispectral remote sensing images using random walks,” *Remote Sensing*, vol. 9, no. 5, 2017.
- [160] A. Vidal and M. R. Moreno, “Change detection of isolated housing using a new hybrid approach based on object classification with optical and TerraSAR-X data,” *International Journal of Remote Sensing*, vol. 32, no. 24, pp. 9621–9635, 2011.
- [161] S.-H. Reza, H. Saeid, and S. Abdolreza, “A hybrid kernel-based change detection method for remotely sensed data in a similarity space,” *Remote Sensing*, vol. 7, no. 10, pp. 12 829–12 858, 2015.
- [162] Z. ZhiMing, V. Lieven, D. C. Eva, O. XiaoKun, and D. W. Robert, “Vegetation change detection using artificial neural networks with ancillary data in Xishuangbanna, Yunnan province, China,” *Chinese Science Bulletin*, vol. 52, no. 2, pp. 232–243, 2007.

-
- [163] J. Rogan, J. Franklin, and D. A. Roberts, “A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery,” *Remote Sensing of Environment*, vol. 80, no. 1, pp. 143–156, 2002.
- [164] F. Kressler and K. Steinnocher, “Change detection in urban areas using satellite data and spectral mixture analysis,” in *International Archives of Photogrammetry and Remote Sensing*, vol. XXXI/B7, 1996, pp. 379–383.
- [165] J. M. Piwowara, D. R. Peddleab, and E. F. LeDrew, “Temporal mixture analysis of Arctic sea ice imagery: A new approach for monitoring environmental change,” *Remote Sensing of Environment*, vol. 63, no. 3, pp. 195–207, 1998.
- [166] J. C. Souza and P. Barreto, “An alternative approach for detecting and monitoring selectively logged forests in the Amazon,” *International Journal of Remote Sensing*, vol. 21, no. 1, pp. 173–179, 2000.
- [167] D. Lu, P. Mausel, E. Brondízio, and E. Moran, “Classification of successional forest stages in the Brazilian Amazon basin,” *Forest Ecology and Management*, vol. 181, no. 3, pp. 301–312, 2003.
- [168] W. Fan, J. Li, and Q. Liu, “GOST2: The improvement of the canopy reflectance model GOST in separating the sunlit and shaded leaves,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 4, pp. 1423–1431, 2015.
- [169] C. Gu, X. Tian, and Z. Li, “Vertical canopy cover retrieval for greater Khingan forest based on a geometric-optical model using Landsat data,” in *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, pp. 4434–4437.
- [170] M. Brown, H. G. Lewis, and S. R. Gunn, “Linear spectral mixture models and support vector machines for remote sensing,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, no. 5, pp. 2346–2360, 2000.
- [171] K. J. Guilfoyle, M. L. Althouse, and C.-I. Chang, “A quantitative and comparative analysis of linear and nonlinear spectral mixture models using radial basis function neural networks,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 10, pp. 2314–2318, 2001.
- [172] F. Chen, K. Wang, and T. F. Tang, “Spectral unmixing using a sparse Multiple-Endmember Spectral Mixture Model,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 5846–5861, 2016.

- [173] C. Shi and L. Wang, “Linear spatial spectral mixture model,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 6, pp. 3599–3611, 2016.
- [174] P. Bicheron and M. Leroy, “A method of biophysical parameter retrieval at global scale by inversion of a vegetation reflectance model,” *Remote Sensing of Environment*, vol. 67, no. 3, pp. 251–266, 1999.
- [175] G. C. Valls, J. M. Mari, L. G. Chova, K. Richter, and J. C. Maravilla, “Biophysical parameter estimation with a semisupervised support vector machine,” *IEEE Geoscience and Remote Sensing Letters*, vol. 6, no. 2, pp. 248–252, 2009.
- [176] C. P. Lo and R. L. Shipman, “A GIS approach to land-use change dynamics detection,” *Photogrammetric Engineering & Remote Sensing*, vol. 56, no. 1, pp. 1483–1491, 1990.
- [177] Ü. Köylü and A. Geymen, “GIS and remote sensing techniques for the assessment of the impact of land use change on runoff,” *Arabian Journal of Geosciences*, vol. 9, no. 7, p. 484, 2016.
- [178] B. Abuelaish and M. T. C. Olmedo, “Scenario of land use and land cover change in the Gaza strip using remote sensing and GIS models,” *Arabian Journal of Geosciences*, vol. 9, no. 4, p. 274, 2016.
- [179] X. Yang and C. P. Lo, “Using a time series of satellite imagery to detect land use and land cover changes in the Atlanta, Georgia metropolitan area,” *International Journal of Remote Sensing*, vol. 23, no. 9, pp. 1775–1798, 2002.
- [180] T. A. Stone and P. Lefebvre, “Using multi-temporal satellite data to evaluate selective logging in Para, Brazil,” *International Journal of Remote Sensing*, vol. 19, no. 13, pp. 2517–2526, 1998.
- [181] T. R. Loveland, T. L. Sohl, S. V. Stehman, A. L. Gallant, K. L. Sayler, and D. E. Napton, “A strategy for estimating the rates of recent United States land-cover changes,” *Photogrammetric Engineering & Remote Sensing*, vol. 68, no. 10, pp. 1091–1099, 2002.
- [182] A. Rikalovic, I. Cosic, R. D. Labati, and V. Piuri, “Intelligent decision support system for industrial site classification: A GIS-Based hierarchical Neuro-Fuzzy approach,” *IEEE Systems Journal*, vol. PP, no. 99, pp. 1–12, 2017.
- [183] L. R. G. Martin, “Accuracy assessment of Landsat-based visual change detection methods applied to the rural-urban fringe,” *Photogrammetric Engineering & Remote Sensing*, vol. 55, no. 2, pp. 209–215, 1989.

-
- [184] J. F. Mas, R. L. Rodríguez, R. G. López, J. L. Sánchez, A. P. Garduño, and E. H. Flores, “Land use/land cover change detection combining automatic processing and visual interpretation,” *European Journal of Remote Sensing*, vol. 50, no. 1, pp. 626–635, 2017.
- [185] G. M. Henebry, “Detecting change in grasslands using measures of spatial dependence with Landsat TM data,” *Remote Sensing of Environment*, vol. 46, no. 2, pp. 223–234, 1993.
- [186] F. Wang, “A knowledge-based vision system for detecting land changes at urban fringes,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 31, no. 1, pp. 136–145, 1993.
- [187] R. L. Lawrence and W. J. Ripple, “Calculating change curves for multitemporal satellite imagery: Mount St. Helens 1980-1995,” *Remote Sensing of Environment*, vol. 67, no. 3, pp. 309–319, 1999.
- [188] Q. Zhang, J. Wang, X. Peng, P. Gong, and P. Shi, “Urban built-up land change detection with road density and spectral information from multi-temporal Landsat TM data,” *International Journal of Remote Sensing*, vol. 23, no. 15, pp. 3057–3078, 2002.
- [189] G. Cao, L. Zhou, and Y. Li, “A new change-detection method in high-resolution remote sensing images based on a conditional random field model,” *International Journal of Remote Sensing*, vol. 37, no. 5, pp. 1173–1189, 2016.
- [190] J. Zheng and H. You, “A new model-independent method for change detection in multitemporal SAR images based on Radon transform and Jeffrey divergence,” *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 1, pp. 91–95, 2013.
- [191] W. K. Michener and P. F. Houhoulis, “Detection of vegetation changes associated with extensive flooding in a forested ecosystem,” *Photogrammetric Engineering & Remote Sensing*, vol. 63, no. 12, pp. 1363–1374, 1997.
- [192] A. S. Dhakal, T. Amada, M. Aniya, and R. R. Sharma, “Detection of areas associated with flood and erosion caused by a heavy rainfall using multitemporal Landsat TM data,” *Photogrammetric Engineering & Remote Sensing*, vol. 68, no. 3, pp. 233–239, 2002.
- [193] T. Fung and E. LeDrew, “The determination of optimal threshold levels for change detection using various accuracy indices,” *Photogrammetric Engineering & Remote Sensing*, vol. 54, no. 10, pp. 1449–1454, 1988.

- [194] L. Bruzzone and D. F. Prieto, “Automatic analysis of the difference image for unsupervised change detection,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, no. 3, pp. 1171–1182, 2000.
- [195] S. Singh and R. Talwar, “Performance analysis of different threshold determination techniques for change vector analysis,” *Journal of the Geological Society of India*, vol. 86, no. 1, pp. 52–58, 2015.
- [196] J. Cihlar and J. Howarth, “Detection and removal of cloud contamination from AVHRR images,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, no. 3, pp. 583–589, 1994.
- [197] J. J. Simpson and J. R. Stitt, “A procedure for the detection and removal of cloud shadow from AVHRR data over land,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 3, pp. 880–897, 1998.
- [198] Z. Li, A. Khananian, R. H. Fraser, and J. Cihlar, “Automatic detection of fire smoke using artificial neural networks and threshold approaches applied to AVHRR imagery,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 9, pp. 1859–1870, 2001.
- [199] J. A. T. Arriaza, F. G. Rojas, M. P. Lopez, and M. Canton, “Competitive neural-net-based system for the automatic detection of oceanic mesoscalar structures on AVHRR scenes,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, no. 4, pp. 845–852, 2003.
- [200] J. Peters, T. Bolch, A. Gafurov, and N. Prechtel, “Snow cover distribution in the Aksu Catchment (Central Tien Shan) 1986-2013 based on AVHRR and MODIS data,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 11, pp. 5361–5375, 2015.
- [201] X. Zhan, R. A. Sohlberg, J. R. G. Townshend, C. DiMiceli, M. L. Carroll, J. C. Eastman, M. C. Hansen, and R. S. DeFries, “Detection of land cover changes using MODIS 250 m data,” *Remote Sensing of Environment*, vol. 83, no. 1, pp. 336–350, 2002.
- [202] S. Biswas, K. D. Lasko, and K. P. Vadrevu, “Fire disturbance in tropical forests of Myanmar-analysis using MODIS satellite datasets,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 5, pp. 2273–2281, 2015.

-
- [203] Z. Lin, F. Chen, B. Li, B. Yu, Z. Shirazi, Q. Wu, and W. Wu, “FengYun-3C VIRR active fire monitoring: Algorithm description and initial assessment using MODIS and Landsat data,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 11, pp. 6420–6430, 2017.
- [204] F. Yuan, K. E. Sawaya, B. C. Loeffelholz, and M. E. Bauer, “Land cover classification and change analysis of the Twin Cities (Minnesota) metropolitan area by multitemporal Landsat remote sensing,” *Remote Sensing of Environment*, vol. 98, no. 2, pp. 317–328, 2005.
- [205] N. Boulghobra, T. Hadri, and M. Bouhana, “Using Landsat imagery for monitoring the spatiotemporal evolution of sanding in dryland, the case of In-salah in the Tidikelt (southern Algerian Sahara),” *Geographia Technica*, vol. 9, no. 1, pp. 1–9, 2014.
- [206] P. F. Houhoulis and W. K. Michener, “Detecting wetland change: A rule-based approach using NWI and SPOT-XS data,” *Photogrammetric Engineering & Remote Sensing*, vol. 66, no. 2, pp. 205–211, 2000.
- [207] K. J. Bhang and S. S. Park, “Evaluation of the surface temperature variation with surface settings on the urban heat island in Seoul, Korea, using Landsat-7 ETM+ and SPOT,” *IEEE Geoscience and Remote Sensing Letters*, vol. 6, no. 4, pp. 708–712, 2009.
- [208] P. Zhang, Z. Lv, and W. Shi, “Local spectrum-trend similarity approach for detecting land-cover change by using SPOT-5 satellite images,” *IEEE Geoscience and Remote Sensing Letters*, vol. 11, no. 4, pp. 738–742, 2014.
- [209] R. Xu, H. Zhang, and H. Lin, “Urban impervious surfaces estimation from optical and SAR imagery: A comprehensive comparison,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 9, pp. 4010–4021, 2017.
- [210] K. Spröhnle, E. M. Fuchs, and P. A. Pelizari, “Object-based analysis and fusion of optical and SAR satellite data for dwelling detection in refugee camps,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 5, pp. 1780–1791, 2017.
- [211] W. G. Cochran, *Sampling Techniques*, 3rd ed. New York: John Wiley and Sons, 1977.

- [212] R. G. Congalton, R. G. Oderwald, and R. A. Mead, “Assessing Landsat classification accuracy using discrete multivariate analysis statistical techniques,” *Photogrammetric Engineering & Remote Sensing*, vol. 49, no. 2, pp. 1671–1678, 1983.
- [213] W. D. Hudson and C. W. Ramm, “Correct formulation of the Kappa coefficient of agreement,” *Photogrammetric Engineering & Remote Sensing*, vol. 53, no. 4, pp. 421–422, 1987.
- [214] R. G. Congalton, “A review of assessing the accuracy of classifications of remotely sensed data,” *Remote Sensing of Environment*, vol. 37, no. 1, pp. 35–46, 1991.
- [215] L. L. F. Janssen and F. J. M. V. D. Wel, “Accuracy assessment of satellite derived land-cover data: A review,” *Photogrammetric Engineering & Remote Sensing*, vol. 60, no. 4, pp. 419–426, 1994.
- [216] M. A. Kalkhan, R. M. Reich, and R. L. Czaplewski, “Variance estimates and confidence intervals for the Kappa measure of classification accuracy,” *Canadian Journal of Remote Sensing*, vol. 23, no. 3, pp. 210–216, 1997.
- [217] S. Khorram, *Accuracy assessment of remote sensing derived change detection*. USA: Monograph Series, edited by American Society for Photogrammetry and Remote Sensing (ASPRS), 1999.
- [218] P. C. Smits, S. G. Dellepiane, and R. A. Schowengerdt, “Quality assessment of image classification algorithms for land-cover mapping: A review and a proposal for a cost-based approach,” *International Journal of Remote Sensing*, vol. 20, no. 8, pp. 1461–1486, 1999.
- [219] G. M. Foody, “Status of land cover classification accuracy assessment,” *Remote Sensing of Environment*, vol. 80, no. 1, pp. 185–201, 2002.
- [220] K. G. Russell. G. Congalton, *Assessing the Accuracy of Remotely Sensed Data*, 2nd ed. Boca Raton, USA: CRC Press, 2008.
- [221] J. T. Morisette and S. Khorram, “Accuracy assessment curves for satellite-based change detection,” *Photogrammetric Engineering & Remote Sensing*, vol. 66, no. 7, pp. 875–880, 2000.
- [222] K. Lowell, “An area-based accuracy assessment methodology for digital change maps,” *International Journal of Remote Sensing*, vol. 22, no. 17, pp. 3571–3596, 2001.

-
- [223] J. Cohen, “A coefficient of agreement for nominal scales,” *Educational and Psychological Measurement*, vol. 20, no. 1, pp. 37–46, 1960.
- [224] S. V. Stehman, “Estimating the Kappa coefficient and its variance under stratified random sampling,” *Photogrammetric Engineering & Remote Sensing*, vol. 62, no. 4, pp. 401–407, 1996.
- [225] D. E. Barbara and G. Michael, “The kappa statistic: A second look,” *Computational Linguistics*, vol. 30, no. 1, pp. 95–101, 2004.
- [226] R. G. Pontius, E. Shusas, and M. McEachern, “Detecting important categorical land changes while accounting for persistence,” *Agriculture, Ecosystems & Environment*, vol. 101, no. 2, pp. 251–268, 2004.
- [227] L. Cheng-lin and W. Jian-jun, “Crop drought monitoring using MODIS NDDI over mid-territory of China,” in *2008 IEEE International Geoscience and Remote Sensing Symposium*, vol. 3, July 2008, pp. III–883–III–886.
- [228] M. Martínez, M. E. Martínez, E. Martínez, and D. Renza, “Detection of changes in natural aquifer reservoirs based on the index of drought,” *IEEE Latin America Transactions*, vol. 15, no. 11, pp. 2059–2063, 2017.
- [229] G. Grünthal and R. Wahlström, “Sensitivity of parameters for probabilistic seismic hazard analysis using a logic tree approach,” *Journal of Earthquake Engineering*, vol. 05, no. 03, pp. 309–328, 2001.
- [230] C. J. Friedland, B. J. Adams, and M. L. Levitan, “Results of neighborhood level analysis of structural storm surge damage to residential structures,” in *In 5(th) International Workshop on Remote Sensing Applications to Natural Hazards*, 2007.
- [231] B. Allenbach, R. Andreoli, S. Battiston, C. Bestault, S. Clandillon, K. Fellah, J. B. Henry, C. Meyer, H. Scius, N. Tholey, H. Yesou, and P. de Fraipont, “Rapid EO disaster mapping service: added value, feedback and perspectives after 4 years of charter actions,” in *2005 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2005)*, vol. 6, 2005, pp. 4373–4378.
- [232] J. Inglada and A. Giros, “On the real capabilities of remote sensing for disaster management - feedback from real cases,” in *2004 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2004)*, vol. 2, 2004, pp. 1110–1112.
- [233] U. N. C. on Environment & Development, *UNCED (1992) Managing fragile ecosystems: combating desertification and drought*. Rio de Janeiro, Brazil: Chapman & Hall, 1992.

- [234] A. Aubreville, *Climats, forêts, et desertification de l'Afrique Tropicale*. France: Société d'Éditions Géographiques, Maritimes et Coloniales, 1949.
- [235] W. J. Carper, T. M. Lillesand, and R. W. Kiefer, "Use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image data," *Photogrammetric Engineering & Remote Sensing*, vol. 56, no. 4, pp. 459–467, 1990.
- [236] N. Kosaka, T. Akiyama, B. Tsai, and T. Kojima, "Forest type classification using data fusion of multispectral and panchromatic high-resolution satellite imageries," in *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS '05.*, vol. 4, 2005, pp. 2980–2983.
- [237] Z. Wang, D. Ziou, C. Armenakis, D. Li, and Q. Li, "A comparative analysis of image fusion methods," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 6, pp. 1391–1402, 2005.
- [238] T. Ranchin and L. Wald, "Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation," *Photogrammetric Engineering & Remote Sensing*, vol. 66, no. 1, pp. 49–61, 2000.
- [239] G. R. Taylor, P. Hemphill, D. Currie, T. Broadfoot, and R. L. Dehaan, "Mapping dryland salinity with hyperspectral imagery," in *IEEE 2001 International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 1, 2001, pp. 302–304.
- [240] H. Kaufmann, S. Chabrillat, J. Hill, M. Langemann, A. Müller, and K. Staenz, "SAND - a hyperspectral sensor for the analysis of dryland degradation," in *IEEE International Geoscience and Remote Sensing Symposium*, 2002, pp. 986–988.
- [241] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 8, pp. 1778–1790, 2004.
- [242] E. S. Chuvieco, *Teledetección ambiental: la observación de la tierra desde el espacio*. Barcelona, Spain: Editorial Ariel, 2010.
- [243] Landsat Missions Timeline, NASA, United States Geological Survey, USA. 2018. [Online]. Available: <https://landsat.usgs.gov/landsat-missions-timeline>
- [244] K. Thome. Terra informations, NASA, Earth Observing System, USA. 2018. [Online]. Available: <https://terra.nasa.gov>
- [245] Sentinel-2, ESA, EU. 2018. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>

-
- [246] SPOT Satellite Imagery, AIRBUS, EU. 2018. [Online]. Available: <https://www.intelligence-airbusds.com/en/143-spot-satellite-imagery>
- [247] Sentinel-1, ESA, EU. 2018. [Online]. Available: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1>
- [248] TerraSAR-X and TanDEM-X, AIRBUS, EU. 2018. [Online]. Available: <https://www.intelligence-airbusds.com/terrasar-x/>
- [249] ENVI, Version: 5.0, Harris Geospatial Solutions, Inc., USA. 2018. [Online]. Available: <https://www.harrisgeospatial.com/SoftwareTechnology/ENVI.aspx>
- [250] R. Richter, “Some aspects of the atmospheric radiance model of LOWTRAN 6,” *International Journal of Remote Sensing*, vol. 6, no. 11, pp. 1773–1777, 1985.
- [251] R. Reji and R. Vidya, “Comparative analysis in satellite image registration,” in *2012 IEEE International Conference on Computational Intelligence and Computing Research*, 2012, pp. 1–6.
- [252] J. S. Lee, J. H. Wen, T. L. Ainsworth, K. S. Chen, and A. J. Chen, “Improved sigma filter for speckle filtering of SAR imagery,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 1, pp. 202–213, 2009.
- [253] J. S. Lee and E. Pottier, *Polarimetric radar imaging: from basics to applications*. CRC Press, Taylor & Francis Group, 2009.
- [254] J. S. Lee, “Digital image smoothing and the sigma filter,” *Computer Vision, Graphics, and Image Processing*, vol. 24, no. 2, pp. 255–269, 1983.
- [255] U. C. Benz, P. Hofmann, G. Willhauck, I. Lingenfelder, and M. Heynen, “Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 58, no. 3, pp. 239–258, 2004.
- [256] B. Thomas, B. Charles, and P. Anssi, *Image Segmentation Methods for Object-based Analysis and Classification*. Dordrecht: Springer Netherlands, 2004, pp. 211–236.
- [257] W. Zhou and A. Troy, “An object-oriented approach for analysing and characterizing urban landscape at the parcel level,” *International Journal of Remote Sensing*, vol. 29, no. 11, pp. 3119–3135, 2008.
- [258] P. Ghamisi, M. D. Mura, and J. A. Benediktsson, “A survey on spectral-spatial classification techniques based on attribute profiles,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 5, pp. 2335–2353, 2015.

- [259] R. M. Haralick, K. Shanmugam, and I. Dinstein, “Textural features for image classification,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610–621, 1973.
- [260] P. Ghamisi, J. A. Benediktsson, and J. R. Sveinsson, “Automatic spectral-spatial classification framework based on attribute profiles and supervised feature extraction,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 9, pp. 5771–5782, 2014.
- [261] T. F. Wu, C. J. Lin, and R. C. Weng, “Probability estimates for multi-class classification by pairwise coupling,” *The Journal of Machine Learning Research*, vol. 5, pp. 975–1005, 2004.
- [262] C. C. Chang and C. J. Lin, “LIBSVM: A library for support vector machines,” *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, no. 3, pp. 27:1–27:27, 2011.
- [263] D. Coomans and D. L. Massart, “Alternative k-nearest neighbour rules in supervised pattern recognition: Part 1. k-nearest neighbour classification by using alternative voting rules,” *Analytica Chimica Acta*, vol. 136, pp. 15–27, 1982.
- [264] A. Malhi and R. X. Gao, “PCA-based feature selection scheme for machine defect classification,” *IEEE Transactions on Instrumentation and Measurement*, vol. 53, no. 6, pp. 1517–1525, 2004.
- [265] S. Aronoff, “Classification accuracy: A user approach,” *Photogrammetric Engineering & Remote Sensing*, vol. 48, no. 8, pp. 1299–1307, 1982.
- [266] M. Story and R. G. Congalton, “Accuracy assessment: A user’s perspective,” *Photogrammetric Engineering & Remote Sensing*, vol. 52, no. 3, pp. 397–399, 1986.
- [267] S. V. Stehman, “Selecting and interpreting measures of thematic classification accuracy,” *Remote Sensing of Environment*, vol. 62, no. 1, pp. 77–89, 1997.
- [268] A. K. Braimoh, “Random and systematic land-cover transitions in northern Ghana,” *Agriculture, Ecosystems & Environment*, vol. 113, no. 1, pp. 254–263, 2006.
- [269] USGS. Global Visualization Viewer (GloVis). 2014. [Online]. Available: <http://glovis.usgs.gov/>
- [270] W. Y. Yan and A. Shaker, “Radiometric correction and normalization of airborne LiDAR intensity data for improving land-cover classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 12, pp. 7658–7673, 2014.

- [271] M. K. Tolba, “Desertification in Africa,” *Land Use Policy*, vol. 3, no. 4, pp. 260–268, 1986.
- [272] H. Benmessaoud, F. Chergui, R. Sahnouni, and C. Chafai, “The potential of geomatics in the realization of a map of desertification sensitivity Southern Massif Belezma - Batna - (Algeria),” *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XL-7/W3, pp. 751–756, 2015.
- [273] M. Saifi, N. Boulghobra, and L. Fattoum, “The Green Dam in Algeria as a tool to combat desertification,” *Planet@Risk*, vol. 3, no. 1, pp. 68–71, 2015.
- [274] D. Nedjraoui and S. Bédrani, “La désertification dans les steppes algériennes : causes, impacts et actions de lutte,” *VertigO - la revue électronique en sciences de l’environnement*, vol. 8, no. 1, pp. 1–15, 2008.
- [275] M. Mostefaoui, *Assessment and analysis of desertification trajectories from 1987 to 2015 in Biskra, the Steppe Region of Algeria*. 789 East Eisenhower Parkway, USA: ProQuest, 2017.
- [276] G. M. Afrasinei, M. T. Melis, C. Buttau, J. M. Bradd, C. Arras, and G. Ghiglieri, “Assessment of remote sensing-based classification methods for change detection of salt-affected areas (Biskra area, Algeria),” *Journal of Applied Remote Sensing*, vol. 11, pp. 11–28, 2017.
- [277] L. Ouerdachi, H. Boutaghane, R. Hafsi, T. B. Tayeb, and F. Bouzahar, “Modeling of underground dams application to planning in the semi arid areas (Biskra, Algeria),” *Energy Procedia*, vol. 18, pp. 426–437, 2012.
- [278] M. Tahar and L. Boureboune, “Anthropic actions and desertification in Algeria,” in *Desertification and Risk Analysis Using High and Medium Resolution Satellite Data*. Dordrecht: Springer Netherlands, 2009, pp. 3–18.
- [279] H. Zhang, H. Lin, and Y. Li, “Impacts of feature normalization on optical and SAR data fusion for land use/land cover classification,” *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 5, pp. 1061–1065, 2015.
- [280] J. Neha, B. Matthias, E. Andrea, F. Rasmus, G. Kenneth, H. Patrick, J. M. Rudbeck, K. Tobias, M. Patrick, M. T. A. Edward, R. Johannes, R. M. Casey, and W. Björn, “A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring,” *Remote Sensing*, vol. 8, no. 1, 2016.
- [281] Copernicus Open Access Hub, ESA, EU. 2018. [Online]. Available: <https://scihub.copernicus.eu/>

- [282] J. Srinivasulu and A. V. Kulkarni, “Estimation of spectral reflectance of snow from IRS-1D LISS-III sensor over the Himalayan terrain,” *Journal of Earth System Science*, vol. 113, no. 1, pp. 117–128, 2004.
- [283] C. C. Chang and C. J. Lin, “Training V-support vector classifiers: Theory and algorithms,” *Neural Computation*, vol. 13, no. 9, pp. 2119–2147, 2001.