



**UNIVERSIDAD DEL AZUAY**

**MAESTRÍA EN GEOMÁTICA CON MENCIÓN EN ORDENAMIENTO TERRITORIAL**

**" EVALUACIÓN DE MÉTODOS DE CLASIFICACIÓN BASADOS EN PÍXELES Y EN  
OBJETOS PARA LA OBTENCIÓN DE MAPAS DE USO Y COBERTURA DEL SUELO A  
PARTIR DE IMÁGENES SATELITALES RAPIDEYE."**

Diseño del Trabajo de Graduación previo a la obtención del título de Posgrado de  
Magister en Geomática con Mención en Ordenamiento Territorial

**Autor:** Luis Ramiro Lazo Pillaga

**Directora:** PhD M<sup>a</sup> del Pilar Martín Isabel

**Codirectora:** PhD M<sup>a</sup> Flor Álvarez Taboada

**Cuenca, Ecuador 2014**

**DEDICATORIA**

A mi Ainy, Andrés y M<sup>a</sup> Eugenia, seres maravillosos en mi vida, que a pesar de las dificultades de la vida, con sus tiernas sonrisas y sacrificio de esposa me han sabido apoyar y ser la fuerza que ha permitido culminar con alegría este trabajo.

A mis padres ejemplares Marcial Lazo, Manuel Duchi, Mercedes Pillaga y Luz Tenelema, por su gran apoyo, sacrificio y esfuerzo.

A mi familia y amigos que directa o indirectamente siempre han estado conmigo apoyándome y brindado su mano sincera para seguir hacia adelante.

## **AGRADECIMIENTO**

A mi Dios, mi gran fortaleza en mi vida.

A mis directoras de tesis, PhD M<sup>a</sup> del Pilar Martín Isabel y PhD M<sup>a</sup> Flor Álvarez Taboada, profesionales ejemplares que a pesar de la distancia han buscado la manera de apoyarme y compartir sin menguar su sabiduría y conocimientos, siempre dispuesto a responder mis inquietudes, gracias por esa predisposición desinteresada, por esa voluntad, paciencia y sobre todo gracias por su amistad sincera.

Al Msc. Omar Delgado director de la Maestría, un profesional y amigo con muchos dotes de enseñanza, siempre paciente y exigente buscando el bienestar de los demás, gracias por su apoyo incondicional.

A todos mis compañeros de la Maestría y profesores que de una y otra manera siempre me han apoyado, gracias por compartir sus conocimientos, por ese compañerismo verdadero y desinteresado, por enseñarme que trabajar en grupo es la mejor arma para hacer frente a las dificultades.

## RESUMEN

La clasificación digital de imágenes de satélite se ha convertido en una herramienta indispensable en la planificación y gestión del territorio, que ayudan a la toma de decisiones en los diferentes niveles de gobierno.

Debido a los errores que se observan a menudo en los mapas derivados del análisis de datos de percepción remota, existe una búsqueda constante por desarrollar y probar alternativas que permitan la obtención de resultados precisos para la toma de decisiones. En el presente documento se da a conocer los resultados de la investigación realizada como trabajo de grado, cuyo propósito fue evaluar y comparar el método de clasificación convencional basada en píxeles individuales frente al método alternativo basado en objetos, en la identificación de diferentes clases de cobertura del suelo a partir de imágenes multiespectrales de muy alta resolución espacial. Los métodos de clasificación evaluados son: a) Algoritmo de máxima probabilidad basado en píxeles (MVS), y b) algoritmo del vecino más próximo (NN) empleando análisis de imágenes basado en objetos (OBIA). Al tratarse de una metodología novedosa para la obtención de información temática, se realizó un estudio piloto a nivel de microcuenca y se utilizó para ello las imágenes obtenidas por el satélite RapidEye sobre la zona de interés, previamente corregidas y proporcionadas por la SENAGUA, se definió una única leyenda temática común para los dos métodos propuestos, se realizó las clasificaciones digitales basadas en píxeles y en objetos utilizando para ello programas comerciales y, finalmente, se realizó una evaluación y comparación de los resultados obtenidos para determinar cuál de ellos presenta una mejor exactitud temática desde el punto de vista cuantitativo y cualitativo.

Como resultado final se obtuvo los mapas temáticos de uso y cobertura de suelo de la microcuenca del río Paute quebrada Jordán, se presenta los resultados obtenidos con los dos métodos de clasificación, se obtuvo conclusiones del método más apropiado para realizar la extracción de información de la cobertura y usos del suelo y se obtuvo el porcentaje de fiabilidad que presenta la cartografía temática generada.

**Palabras clave:** Máxima verosimilitud, clasificación basada en objetos, RapidEye, cartografía de usos y ocupación del suelo.

## ABSTRACT

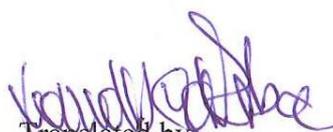
The digital classification of satellite images has become an indispensable tool in the planning and land management to help decision making at different government levels. Due to errors that are often seen on maps derived from analysis of remote sensing data, there is a constant search to develop and test alternatives to obtaining accurate results for decision-making. This paper shows the results of the research conducted as an undergraduate work whose purpose was to evaluate and compare the conventional classification method based on individual pixels versus the alternative method based on objects in regard to the identification of different types of ground coverage from multispectral images of very high spatial resolution.

The classification methods evaluated by using object-based image analysis (OBIA) are: a) Maximum likelihood algorithm based on pixels (MVS), b) Nearest neighbor algorithm (NN). Due to the fact that this is a novel methodology for obtaining thematic information, a pilot study at micro level was conducted by using the images obtained by the Rapid-Eye satellite over the area of interest, previously corrected and supplied by SENAGUA (National Water Secretariat). One common thematic legend for both proposed methods was defined; the digital classifications based on pixels and objects was performed by using commercial software; and finally an evaluation and comparison of the results obtained was performed to determine which of them has better thematic accuracy from the point of quantity and quality.

As a final result, the thematic maps of land use and land cover of the *Paute River Jordán* gorge Micro watershed were obtained. The results attained with the two methods of classification are presented; the conclusions of the most appropriate method for land use and land cover data collection were obtained, attaining the percentage of reliability showed by the generated thematic mapping.

**Keywords:** Maximum Likelihood, Object-Based Classification, Rapid-Eye, Land Use and Land Cover Mapping.



  
Translated by,  
Lic. Lourdes Crespo

## Índice de contenidos

DEDICATORIA.....	ii
AGRADECIMIENTO .....	iii
RESUMEN .....	iv
Palabras clave:.....	iv
ABSTRACT .....	v
keywords .....	v
1. INTRODUCCIÓN .....	7
2. HIPÓTESIS .....	8
3. PROBLEMÁTICA .....	8
4. OBJETIVOS .....	9
4.1 Objetivo general .....	9
4.2 Objetivos específicos .....	10
5. MATERIALES Y METODOS .....	11
5.1 Materiales.....	11
5.2 Área de estudio .....	11
5.3 Pre-procesamiento de imagen .....	12
5.4 Generación de información espectral derivada .....	13
5.5 Clasificación digital.....	14
5.5.1 Definición de la leyenda temática .....	14
5.5.2 Clasificación Supervisada Basada en Píxeles .....	15
5.5.3 Clasificación Supervisada Basada en Objetos .....	17
5.6 Evaluación de la exactitud o validación .....	20
6. RESULTADOS Y DISCUSIÓN .....	21
6.1 Fase de entrenamiento .....	21
6.2 Segmentación .....	23
6.3. Resultados de las clasificaciones de uso y cobertura suelo basadas en píxeles y en objetos de la imagen RapidEye. ....	24
7. VALIDACIÓN.....	27
8. CONCLUSIONES Y RECOMENDACIONES.....	30
9. REFERENCIAS BIBLIOGRÁFICAS .....	31

## Índice de figuras y tablas

Fig. 1. Localización del área en estudio.....	12
Fig. 2. Imagen satelital RapidEye del área de estudio (composición falso color 532). .....	13
Fig. 3. Distribución espacial de objetos y píxeles en la imagen RapidEye .....	22
Fig. 4. Imagen RapidEye en falso color (Izq.) y un ejemplo de segmentación empleando el parámetro escala 10, criterio de forma 0.2 y compacidad 0.5 (D.) .....	23
Fig. 5.- Representación gráfica de las áreas obtenidas de la clasificación basada en píxeles y en objetos de la imagen RapidEye en color verdadero de toda el área de estudio (a) y en falso color a diferentes escalas (b). .....	24
Fig. 6. Representación gráfica de los resultados de las áreas en porcentaje de las clasificaciones basadas en píxeles y en objetos de la imagen RapidEye. ....	26
Fig. 7. Resultado comparativo de las fiabilidades obtenidas por los dos métodos de clasificación. ....	28
Tabla 1. Categorías de clasificación de uso y cubierta del suelo .....	15
Tabla 2. Numero de áreas de entrenamiento en píxeles por categoría .....	21
Tabla 3. Cantidad de objetos por categoría temática .....	21
Tabla 4. matriz de separabilidad según la DT de las áreas de entrenamiento definidas en la imagen RapidEye. ....	22
Tabla 5. Orden de separabilidad según la DT .....	23
Tabla 6. Superficie ocupada por cada clase de cubierta/uso a partir de la clasificación basada en píxeles y en objetos de la imagen RapidEye. ....	25
Tabla 7. Matriz de confusión de la clasificación basada en píxeles .....	27
Tabla 8. Matriz de confusión de la clasificación basada en objetos. ....	27
Tabla 9. Resultado comparativo de la matrices de confusión .....	28

Luis Ramiro Lazo Pillaga  
Trabajo de graduación  
M<sup>a</sup> del Pilar Martín Isabel  
M<sup>a</sup> Flor Álvarez Taboada  
Noviembre, 2014

## 1. INTRODUCCIÓN

Una de las aplicaciones más comunes de imágenes procedentes de sensores remotos es la extracción de información de la cobertura y usos del suelo. Dicha información se utiliza para generar información de interés que ayude a la toma de decisiones de los diferentes gobiernos, ya sea para optimizar la planificación y gestión del territorio, la gestión de riesgos, la elaboración de estudios ecológicos y ambientales o el establecimiento de tasas de deforestación, entre muchos otros; tanto en ambientes urbanos como rurales y/o agrícolas.

Actualmente los requerimientos de información espacial de gran calidad representan una de las necesidades más comunes en todas las actividades humanas, pues es necesario y relevante conocer con mayor exactitud y velocidad los cambios que se originan sobre la superficie terrestre (Ardila et al., 2005). En el ámbito de la planificación, existe una gran demanda de información espacial de alto nivel de detalle, demanda que es cubierta en gran parte por la información proveniente de imágenes satelitales.

La forma tradicional de extracción de información temática en imágenes satelitales es la clasificación basada en píxeles, que se ha empleado de forma generalizada en todo tipo de proyectos desde los inicios de la interpretación de imágenes asistida por computador, en la década de los setenta (Chuvieco, 2010). Los métodos más utilizados para la clasificación de imágenes satelitales por los profesionales en el Ecuador que trabajan en instituciones relacionadas a la temática son los métodos supervisado y no supervisado, ambos basados en píxeles, utilizando programas comerciales y con imágenes de moderada resolución espacial (Mejía y Moncayo, 2012).

Con el aumento de resolución espacial de los nuevos satélites comerciales, las clases de uso del suelo tienden a ser representadas por unidades espaciales de características espectrales muy heterogéneas, y su separabilidad estadística se reduce cuando se utilizan criterios tradicionales de clasificación basados en píxeles. En consecuencia, la precisión de la clasificación se reduce y, por lo general, los resultados muestran un efecto de sal y pimienta, debido a la existencia de píxeles individuales clasificados de forma diferente a sus vecinos. Así pues, la información de uso de suelo extraída mediante la clasificación basada en píxeles de imágenes multiespectrales adquiridas por sensores de alta o muy alta resolución espacial muestra tener más complejidad, debido al aumento de la variación

interna en la unidad de la cubierta vegetal (Ferrón, 2011). Estudios previos han demostrado que la precisión de la clasificación superficie-uso del suelo puede disminuir cuando aumenta la resolución espacial de la imagen, siendo la exactitud de la clasificación particularmente problemática en los entornos agrícolas y urbanos que normalmente consisten en mosaicos de pequeños objetos compuestos de materiales con diferentes propiedades físicas y espectrales (Ardila et al., 2005; Ferrón, 2011).

Ante estas limitaciones, muchas investigaciones se han dirigido a desarrollar nuevos métodos alternativos de clasificación de imágenes de satélite. Entre ellos destacan: a) la clasificación basada en objetos, que consiste en tomar como unidad de análisis grupos de píxeles de características homogéneas, en lugar de píxeles aislados y, b) la clasificación basada en redes neuronales, que permite incorporar diferentes tipos de información (respuesta espectral, modelos de elevación, mapas temáticos) sin restricciones derivadas de la distribución estadística de los datos (García y Mas, 2008).

Algunos autores (Ferrón, 2011; Hay y Castilla, 2006), mencionan que la clasificación basada en objetos frente a la basada en píxeles, mejora la precisión de la clasificación digital, debido a que la partición de una imagen en objetos de interés (*IO, Interest Object*) es similar al concepto que tienen los humanos de organizar el paisaje para comprenderlo.

Con los antecedentes expuestos, el objetivo de la investigación propuesta en el presente proyecto es evaluar y comparar el desempeño de dos diferentes métodos de clasificación: convencional (basados en píxeles) y alternativo (basados en objetos) en la identificación de diferentes clases de cobertura del suelo a partir de imágenes multispectrales de muy alta resolución espacial, como las obtenidas por la constelación de satélites RapidEye. Los métodos de clasificación a evaluar son: a) Algoritmo de máxima probabilidad basado en píxeles (MVS), y b) algoritmo del vecino más próximo (NN) empleando análisis de imágenes basado en objetos (OBIA).

## **2. HIPÓTESIS**

La hipótesis que se plantea en la presente investigación es que la clasificación basada en objetos, produce resultados de mayor exactitud y consistencia que la metodología de clasificación convencional basada en píxeles cuando se aplica a imágenes de muy alta resolución espacial, como las obtenidas por RapidEye.

## **3. PROBLEMÁTICA**

Existe en estos momentos en Ecuador un proyecto que pretende encaminar a la soberanía energética del país con la generación de energía eléctrica a través de recursos hídricos de la cuenca del río Paute (CELEC EP- Hidropaute, 2012). Así, el Complejo Hidroeléctrico Paute Integral (Molino y Mazar) y posterior inclusión de Sopladora y Cardenillo, aportará

con el 35% de la energía al Ecuador. En este contexto, existe la necesidad de contar con información detallada de cobertura vegetal y uso de suelo a escala 1:25.000 de toda la Cuenca del río Paute, herramienta imprescindible para la planificación del territorio y su adecuada gestión desde el punto de vista técnico, social y ambiental.

Varios estudios, tanto de investigación como de consultoría afines al tema, se han realizado dentro de la cuenca del río Paute, sin embargo, ninguno de ellos con el objetivo específico de determinar la cobertura y uso de suelos a detalle. Es así que la cuenca del río Paute cuenta solamente con información de usos a una escala muy pequeña (1:100.000). Revisando varios estudios y proyectos, especialmente los Planes de Desarrollo y Ordenamiento Territorial (PDOT) de los diferentes cantones que forman parte de la cuenca del río Paute, se cuenta con información de usos de suelo a escalas más grandes, con una particularidad de que la mayoría de estos estudios se han realizado mediante métodos de clasificación digital convencional a partir de imágenes procedentes de Áster o Landsat y no presentan un análisis detallado de la calidad de los resultados generados.

El principal problema en las clasificaciones tradicionales, basadas únicamente en la respuesta espectral de los píxeles que conforman la imagen, es la insuficiente información para aislar completamente los elementos del territorio, debido a la complejidad de los mismos, el solape en el comportamiento espectral de algunas cubiertas y sus interacciones con otros objetos adyacentes. Se ha demostrado que la combinación de datos espectrales con otras fuentes de datos (auxiliares) permite mejorar, en ocasiones de forma significativa, las clasificaciones de usos de suelo obtenidas a partir de teledetección (Abkar et al., 2000). En la misma línea, Gong y Howarth (1990), afirman que es importante considerar que los clasificadores convencionales (como el clasificador de máxima-probabilidad y el clasificador de mínima-distancia basado en píxeles) no reconocen los modelos espaciales del mismo modo que el intérprete humano hace. Así pues, resulta evidente la necesidad de contar con otros sistemas auxiliares para mejorar los resultados de dichos clasificadores convencionales. En este sentido, el presente estudio evaluará dos métodos de clasificación digital, con el objetivo de obtener mapas de usos y cobertura vegetal del suelo adaptados a la realidad del territorio a partir de imágenes de muy alta resolución espacial que permitan disponer de cartografía de detalle para las labores de planificación.

## **4. OBJETIVOS**

### **4.1 Objetivo general**

El objetivo principal de este estudio es evaluar el método de clasificación basado en objetos frente a la metodología tradicional de clasificación basada en píxeles individuales para la extracción de información temática sobre la cobertura vegetal y usos de suelo en la cuenca del río Paute a partir de imágenes satelitales RapidEye.

#### **4.2 Objetivos específicos**

- Definir una leyenda temática de uso y cobertura del suelo en la microcuenca del río Paute quebrada Jordán adaptada a las características de la zona y de la imagen a utilizar en la clasificación
  
- Evaluar la idoneidad del método de clasificación basado en píxeles (MVS) utilizando el algoritmo de máxima probabilidad,
- Evaluar el análisis de imágenes basado en objetos (OBIA) utilizando el algoritmo del vecino más próximo (NN) para la identificación de cubiertas y usos del suelo en la microcuenca del río Paute quebrada Jordán.
  
- Validar estadísticamente los resultados obtenidos de las clasificaciones, empleando datos del terreno e información auxiliar procedente de fotografías aéreas de la zona de estudio.

## 5. MATERIALES Y METODOS

### 5.1 Materiales

La imagen utilizada fue adquirida por el sensor Jena Spaceborne Scanner JSS 56 del satélite RapidEye sobre la zona de interés el 21 de julio de 2010. Contiene información en 5 bandas espectrales con una resolución espacial de 5 m y está referida al sistema de Proyección Universal Transversa de Mercator (UTM), zona 17, Datum WGS84. Esta imagen ha sido proporcionada por la Secretaria Nacional del Agua (SENAGUA), Demarcación Hidrográfica del Santiago.

Como elemento adicional a utilizar, tanto en clasificación como en la validación de uso y coberturas determinadas, se incluyen las fotografías aéreas ortorectificadas adquiridas sobre la misma zona también en el año 2010 y con una resolución espacial de 30 cm. Estas fotografías han sido proporcionadas por el programa Sistema Nacional de Información y Gestión de Tierras Rurales e Infraestructura Tecnológica (SIGTIERRAS) del Ministerio de Agricultura, Ganadería Acuacultura y Pesca (MAGAP).

Para el procesamiento digital de la imagen RapidEye se han utilizado en este proyecto las siguientes herramientas informáticas: a) para realizar la clasificación basada en pixel se utilizó el software de procesamiento de imágenes ENVI Versión 5.0.; b) para la clasificación basada en objetos, el software comercial *eCognition Developer Versión 8.7*; c) finalmente para la generación de la cartografía temática se ha utilizado el software ArcMap versión 10.1.

### 5.2 Área de estudio

El estudio se realizó en la “*Microcuenca del Río Paute Q. Jordán*” dentro de la cuenca Hidrográfica del Río Paute. El área de estudio se encuentra en la Provincia del Azuay al sur de Ecuador, en los cantones de Sevilla de Oro y Paute, ubicada dentro de los paralelos -2° 36' 16,276" y -2° 44' 34,988" de latitud sur y -78° 34' 15,021" y -78° 39' 55,242" de longitud oeste abarcando una superficie promedio de 100 km<sup>2</sup> (fig. 1). La zona presenta dos tipos de clima, *Clima Ecuatorial Meso térmico Semi-Húmedo y Húmedo*, y *Ecuatorial de Alta Montaña*. En esta región las precipitaciones promedio son de 1.379,7 mm, siendo los meses de abril, mayo, junio y julio los de mayor precipitación, mientras que entre septiembre y enero las precipitaciones disminuyen. Sin embargo hay que indicar que en todos los meses se registran precipitaciones, lo que permite deducir que no hay un mes ecológicamente seco en la zona. La temperatura promedio oscila entre los 14 y 20 °C (PDOT Sevilla, 2012).

El área de estudio presenta en general y de manera visual características de uso y cobertura bien definidas. En la parte alta se encuentran los páramos húmedos de alta montaña, que se comportan como una fábrica de agua freática que da lugar al nacimiento

de los principales ríos y quebradas que alimentan todo el sistema hídrico, motivo por el cual este ecosistema es conocido como humedal. La zona media presenta una vegetación húmeda interandina, que es el ecosistema más extenso en términos territoriales que se encuentra en la región. Sus características la hacen óptima para el desarrollo de cualquier actividad agrícola. La temperatura, precipitación, humedad relativa del ambiente y calidad edafológica de los suelos han propiciado que sea el área donde se establecen los centros poblados y áreas productivas, con niveles de intervención elevados y alto grado de impacto al ecosistema natural del cantón Sevilla de Oro y por ende del área de estudio. Esta zona está orientada a las actividades agropecuarias, fundamentalmente a la ganadería, abarcando la agricultura y ganadería el 37,05% de la población total del cantón Sevilla de Oro (PDOT Sevilla, 20012).

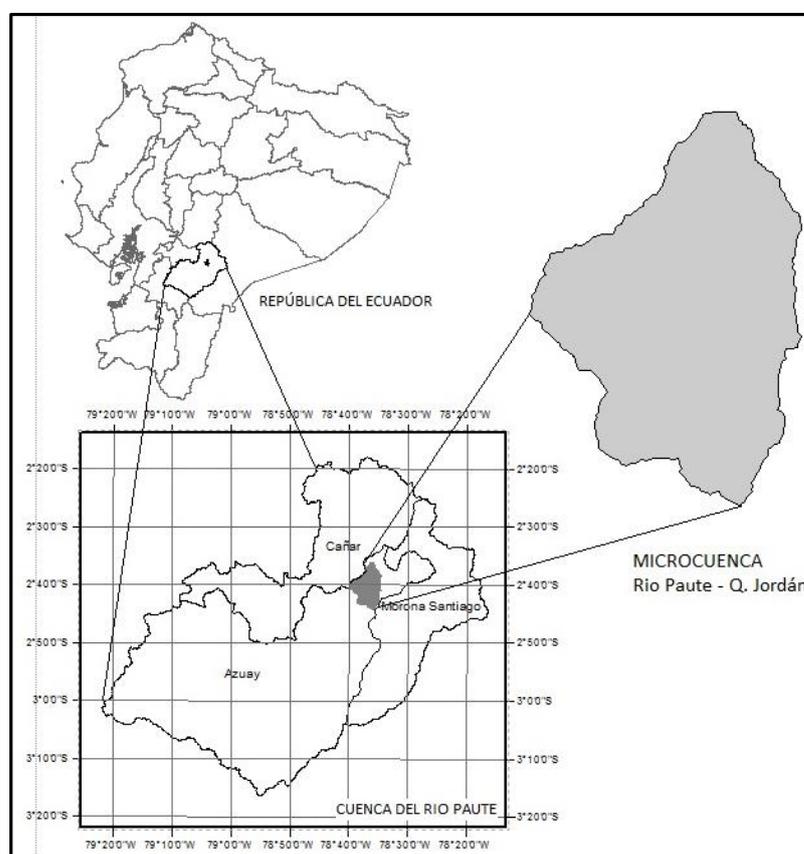


Fig. 1. Localización del área en estudio

### 5.3 Pre-procesamiento de imagen

La imagen satelital RapidEye (fig. 2) se obtuvo previamente corregida geométrica y radiométricamente. Sin embargo, se realizó una comprobación de la calidad de los procesos empleados, especialmente en lo que se refiere a la corrección geométrica, y para ello se utilizaron fotografías aéreas y cartografía detallada como el catastro urbano del

cantón Sevilla de Oro. La imagen satelital RapidEye corresponde a un nivel de proceso 3A (Orthorectificada), corregida geoméricamente utilizando 80 puntos de control tomados con un GPS diferencial (error <40cm) y un Modelo Digital de Elevación (DEM) de resolución espacial de 5m lo que garantiza que existe también una corrección por el sombreado topográfico. La imagen posee una resolución radiométrica de 8 bit correspondiente a 255 niveles de tonalidades (ND), (CGPAUTE, 2011).

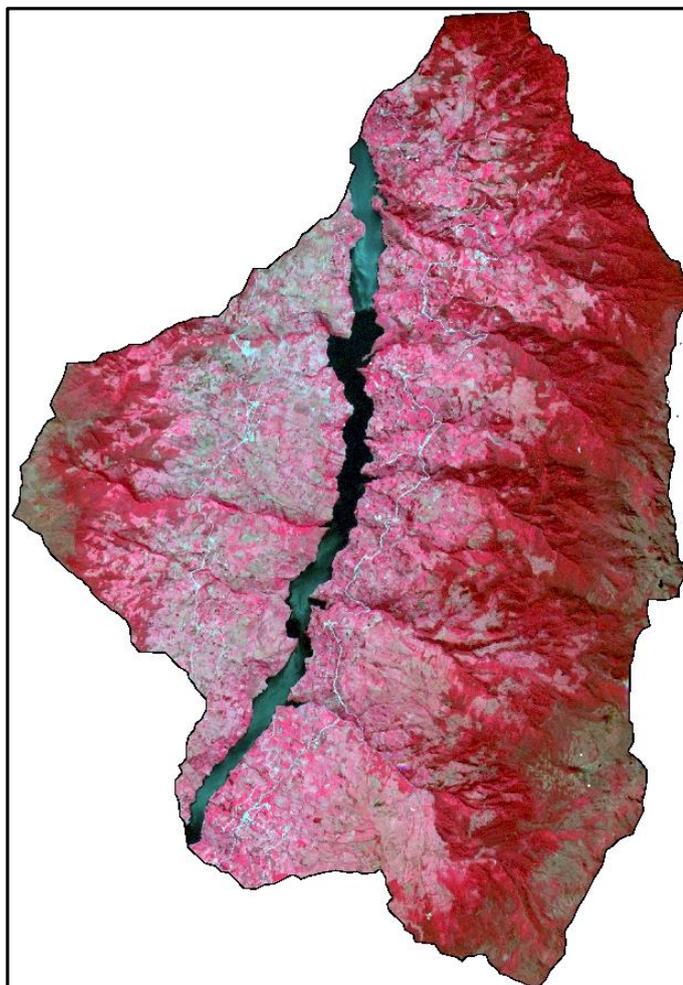


Fig. 2. Imagen satelital RapidEye del área de estudio (composición falso color 532).

#### 5.4 Generación de información espectral derivada

Además de la información contenida en las bandas originales de la imagen se consideró de interés generar información derivada en forma de índices espectrales que pudieran incorporarse a la clasificación para facilitar la separabilidad espectral de las cubiertas. En concreto se calculó el índice NDVI (*Normalized Difference Vegetation Index*) que se basa en la diferencia existente entre la máxima absorción de las cubiertas vegetales en el rojo (690nm), relacionada con la presencia de pigmentos, fundamentalmente de clorofila; y la

máxima reflectividad existente en el infrarrojo cercano (800nm), debida a la estructura celular de la hoja (Haboudane et al., 2004). Este índice es cuantificado según la ecuación:

$$NDVI = (R_{NIR} - R_{RED}) / (R_{NIR} + R_{RED})$$

Siendo  $R_{NIR}$  y  $R_{RED}$  la reflectividad en la banda del infrarrojo cercano (R850nm) y en la del rojo (R685nm), respectivamente.

Por otra parte los satélites RapidEye son los primeros satélites comerciales que ofrecen la capacidad de la banda RedEdge (690nm – 730nm). Esta banda RedEdge es muy sensible para identificar parámetros relacionadas con el estado de la vegetación como por ejemplo el contenido en nitrógeno, el cual se encuentra directamente relacionado con el contenido de clorofila de la planta (Martín, 2011). Así pues, en el presente estudio además del NDVI tradicional se calculó el RedEdge NDVI, según la ecuación:

$$RedEdgeNDVI = (R_{RedEdge} - R_{RED}) / (R_{RedEdge} + R_{RED})$$

Siendo  $R_{RedEdge}$  y  $R_{RED}$  la reflectividad en la banda del *borde rojo* (R730nm) y en la del rojo (R685nm), respectivamente.

Dado que en este trabajo no se pretendía dar un valor físico a los resultados del análisis sino solamente analizar las diferencias espectrales relativas entre píxeles de cara a la clasificación temática de cubiertas, ambos índices se calcularon a partir de los NDs y no sobre los valores de reflectividad lo que nos permitió evitar el complejo proceso de corrección atmosférica. En este caso, tal y como indica Chuvieco (2010), el índice presenta una valoración relativa aunque sigue manteniendo la misma relación con el estado de la vegetación.

## 5.5 Clasificación digital

### 5.5.1 Definición de la leyenda temática

La definición de las categorías temáticas a clasificar se realizó teniendo en cuenta la resolución espectral y espacial del sensor RapidEye, así como las características del territorio y la aplicabilidad de la información temática.

La imagen RapidEye presenta una resolución espacial de 5 m, es decir que, teóricamente se pueden discriminar en la imagen los objetos/cubiertas de tamaño igual o superior a 25 m<sup>2</sup>. Sin embargo, la capacidad de discriminación depende, no sólo del tamaño del objeto observado sino también de sus características espectrales y del contraste con los objetos vecinos. En este sentido Chuvieco (2010) recomienda que la escala límite más idóneo para generar cartografía a partir de sensores de muy alta resolución espacial como RapidEye, es de 1:25.000. Así mismo recomienda que la Mínima Unidad Cartografiable (MUC) no sea

inferior a 4 mm<sup>2</sup>, medidos a escala del mapa, por lo que para la imagen RapidEye la MUC será de 1 ha.

La microcuenca analizada en este trabajo presenta, en general y de manera visual, 3 zonas bien definidas en cuanto a la ocupación del suelo: un porcentaje alto de pastizal, una zona de paramo y otra de vegetación arbustiva y/o arbórea.

De cara a definir una leyenda aplicable y útil a diferentes ámbitos de la gestión, se ha propuesto una leyenda estratificada. Para ello se ha tomado como referencia la leyenda de CORINE Land Cover (<http://www.eea.europa.eu/publications/COR0-landcover>), y las definidas por varias instituciones del país, como el Ministerio del Ambiente (MAE), Ministerio de Agricultura (MAGAP), Centro de Levantamiento Integrado por Sensores Remotos (CLIRSEN.) Se han definido ocho clases de uso y cubierta del suelo, a partir de recorridos de campo y toma de puntos con GPS y fotointerpretación, en la siguiente tabla se detallan las categorías de uso a clasificar (tabla 1):

Tabla 1. Categorías de clasificación de uso y cubierta del suelo

Definición de la leyenda Temática			
Nivel 1	Nivel 2	Nivel 3	Código
Territorio Artificial	Red Vial	Red Vial	1
Territorio Agrícola	Pastos	Pastos en buenas condiciones	2
		Pastos degradado	3
Bosques y áreas Seminaturales	Bosque	Bosque denso	4
	Área con vegetación herbácea y/o Arbustiva	Paramo	5
		Matorral arbustivo	6
	Áreas abiertas, sin o con poca vegetación	Tierra desnuda o en barbecho	7
Superficie de Agua	Aguas Continentales	Agua	8

Como se puede ver en la tabla 1, la leyenda temática se ha estratificado en tres niveles, en el nivel 1 se consideran cuatro categorías de uso y cubierta del suelo, en el nivel 2 seis y en el nivel 3 ocho. Sus agrupaciones se consideran de acuerdo a su finalidad y nivel de detalle, y las características y relación existente de cada categoría y/o vegetación. El nivel de uso y cobertura de suelo utilizado en el presente estudio es el nivel 3 de ocho clases o categorías temáticas.

### 5.5.2 Clasificación Supervisada Basada en Píxeles

**Fase entrenamiento.**- Considerando lo recomendado por Chuvieco (2010), que manifiesta seleccionar un mínimo de  $m+1$  píxel por categoría y de ser posible superar este límite a 10m y 100m por categoría, siendo  $m$  el número de bandas que integra el análisis, en el presente estudio se ha superado este límite de 262 a 664. Para cada categoría temática se obtuvo la caracterización espectral mediante la selección visual de campos de entrenamiento o regiones de interés (ROIs) sobre la imagen RapidEye. Estas zonas de entrenamiento fueron

corroboradas in situ o mediante fotointerpretación de las ortofotos del 2010 proporcionadas por el proyecto SIGTIERRAS.

Una vez definidas las firmas espectrales y antes de abordar el proceso de clasificación propiamente dicho, fue necesario evaluar la viabilidad de que las categorías temáticas definidas pudieran clasificarse sin grave riesgo de error. Como un primer acercamiento a las tendencias espectrales de cada categoría se realizó un análisis del diagrama de firmas. Estos diagramas permiten una primera valoración cualitativa de la separabilidad espectral de las cubiertas. Sin embargo, es conveniente utilizar también otros criterios cuantitativos que permitan evaluar numéricamente la posibilidad de discriminar las distintas clases. En este trabajo se optó por utilizar un cálculo de divergencia estadística denominado *divergencia transformada (DT)* ya que es el método más utilizado en estudios donde se emplea la clasificación de *máxima verosimilitud* (Maussel *et al.*, 1990).

Las ecuaciones siguientes muestran cómo calcular la divergencia y la divergencia transformada. Se pueden consultar de forma detallada en (Swain y Davis, 1978; Chuvieco, 2010).

a. Divergencia:

$$D_{ij} = \frac{1}{2} \text{tr} [(C_i - C_j)(C_i^{-1} - C_j^{-1})] + \frac{1}{2} \text{tr} [(C_i^{-1} - C_j^{-1})(m_i - m_j)(m_i - m_j)^t]$$

b. Divergencia Transformada:

$$DT_{ij} = c [1 - \exp(-D_{ij} / 8)]$$

Siendo:

i y j: medida de las dos firmas espectrales o clases comparadas.

$C_i, C_j$ : las matrices de varianza-covarianza de la firma espectral i y j.

$m_i$  y  $m_j$ : vectores de medias de la firma espectral i y j.

tr: traza de los elementos de la diagonal de la matriz indicada.

t: función de transposición o matriz transpuesta.

c: Valor máximo de la divergencia, señalándose habitualmente un valor de 2.000.

La divergencia estadística parte de la base de que los niveles digitales en una categoría se distribuyen normalmente, considerando la separabilidad como medida del solape entre categorías vecinas. Un valor de divergencia transformada de 2.000 sugiere excelente separación de clases, sobre 1.900 señala una buena separación, mientras que bajo 1.700 indica una pobre separación entre clases (Jensen, 1996).

**Fase de asignación y clasificación.**- Una vez aceptadas las firmas espectrales, se realizó la clasificación con el algoritmo probabilístico de Máxima Verosimilitud, uno de los más comúnmente utilizados en teledetección (Chuvieco, 2010). Para realizar la clasificación se utilizaron siete bandas de entrada: el Rojo(R), Green (G), Blue (B), RedEdge, Infrarrojo

Cercano (NIR), NDVIb5b3 y el NDVIb4b3. En principio el clasificador asume que los datos siguen una función de distribución normal (Gaussiana) para asignar la probabilidad de que un píxel cualquiera pertenezca a cada una de las clases temáticas a partir de la media, la desviación estándar y las matrices de varianza-covarianza de las muestras, así como para todas las bandas que intervienen en la clasificación (Jensen, 2005). A las coberturas obtenidas se les aplicó un filtro de *Majority Analysis* para agrupar píxeles aislados a la clase vecina, y reducir el efecto de “sal y pimienta” y la probabilidad de que píxeles aislados, mal clasificados, sesgaran la evaluación de la confiabilidad post-clasificatoria (Chuvieco, 2010).

### 5.5.3 Clasificación Supervisada Basada en Objetos

El análisis de imágenes basado en objetos (OBIA), se fundamenta en la percepción humana de la realidad como un todo compuesto de unidades básicas de información u objetos organizados y relacionados, más que como partes separadas y aisladas (Ardila et al., 2005).

La particularidad de este tipo de análisis es que la clasificación se realiza en base a objetos y no a píxeles. Al estar la imagen formada por píxeles, el primer paso en OBIA es agrupar estos píxeles en regiones homogéneas que se denominan “objetos”. En este trabajo para ello se ha empleado un proceso de *segmentación*, agrupando los píxeles adyacentes mediante técnicas de regiones crecientes, para posteriormente clasificar los objetos extraídos.

Al trabajar con objetos en lugar de con píxeles el número de variables que se pueden emplear en la clasificación aumenta notablemente, permitiendo considerar criterios como el tamaño, la forma, las características espectrales (color), máximos y mínimos, proximidad a otros objetos, textura, etc. Al mismo tiempo, la segmentación reduce el número de objetos a clasificar, con lo cual el tiempo de procesado también disminuye. El criterio de parada en el proceso de la fusión de regiones se produce gracias al parámetro denominado “escala”, que puede ser definido por el usuario, es decir, los valores más altos para el parámetro de escala generan objetos de imagen más grandes, mientras que valores más pequeños para dicho parámetro producen objetos más pequeños. La segmentación es una de las tareas más complejas de la clasificación basada en objetos y puede determinar el éxito o fracaso del análisis final. (Ferrón, 2011).

Con estas premisas, se optó por emplear el *software eCognition Developer Version 8.7*, comercializado desde el año 2000 y desarrollado por la empresa Definiens Imaging, para llevar a cabo la segmentación y clasificación de la imagen. Se optó por utilizar esta herramienta porque es el software comercial más completo para el análisis de imágenes basado en objetos. Si bien es una técnica relativamente nueva, que está actualmente en desarrollo (Benz et al., 2004, Ferrón, 2011).

**Segmentación de Imagen.-** El algoritmo implantado en eCognition y utilizado para la segmentación debido a su versatilidad en el tratamiento de distintos tipos de imágenes es el algoritmo llamado *Segmentación con Multirresolución* que es una técnica de fusión-región de abajo hacia arriba a partir de objetos formados por píxeles (Baatz y Schäpe, 2000).

El algoritmo de segmentación con multirresolución minimiza la heterogeneidad media de los objetos de la imagen para una resolución o escala dada. El procedimiento de segmentación se inicia considerando cada píxel como un objeto inicial (píxel semilla) uniéndose iterativamente cada píxel semilla con los píxeles adyacentes. Este método genera regiones no determinísticas que, de acuerdo con parámetros de escala y homogeneidad definidos por el usuario, permite generar sobre una imagen objetos irregulares, es decir, de distinto tamaño y con diferente configuración de parámetros, normalmente variaciones espectrales y de forma. La combinación óptima de dichos parámetros dependerá de diversos factores como las resoluciones espacial y espectral de la imagen, el tipo de objetos de interés y las condiciones ambientales en el momento de la toma de la imagen (Castillejo, 2011).

Los parámetros que hay que definir para aplicar el algoritmo de multirresolución son: los datos de entrada (capas de información), el parámetro de escala, y la composición de la homogeneidad (con cuatro subcriterios: color, forma, compacidad y suavidad).

Para la segmentación la imagen RapidEye, se emplearon como datos de entrada las 7 bandas (R,G,B,RedEdge,NIR,NDVib5b3 y NDVI b4b3), con los siguientes pesos: Peso 1 a todas las bandas originales que compone la imagen RapidEye (R,G,B,RedEdge,NIR) y 0 para los NDVIs. Como parámetro de escala se empleó 10, mientras que los valores de los subcriterios de homogeneidad fueron 0.8 para el de color, 0.2 para el de forma, 0.5 para la suavidad y 0.5 para la compacidad. A continuación se describen en que consiste cada uno de estos parámetros:

*Capas de la imagen y pesos.-* La herramienta eCognition permite la selección de las capas de información que van a ser empleadas para la realización de la segmentación. Esto quiere decir que no todas las capas tienen que ser obligatoriamente tenidas en cuenta en este paso. Las capas de la imagen pueden ser ponderadas para considerar su importancia o la idoneidad para el resultado de la segmentación requerida. Cuanto mayor sea el peso asignado a una capa de imagen, más peso se le asignará a la información de los píxeles que la integran durante el proceso de segmentación, en el supuesto de que la segmentación utilizara información de los píxeles. En consecuencia, a las capas de imagen que no contienen la información destinada a la representación de los objetos de interés de la imagen se les debe dar poco o ningún peso.

*El parámetro de escala:* El parámetro de escala es un término abstracto que determina la heterogeneidad máxima permitida para los objetos de la imagen resultante. Esto quiere decir que modificando el valor de este parámetro, se modifica el tamaño de los objetos de la imagen. El objetivo debe ser la producción de los objetos de imagen de la mayor escala posible en los que todavía se distinguen las diferentes regiones de la imagen que deben ser clasificadas.

*Parámetro de Forma:* Este parámetro forma parte del criterio de homogeneidad. El valor del campo "forma" se modifica con la relación entre la forma y el color (información de los niveles digitales), de manera que al modificar el umbral o peso que se le da a la forma, se está cambiando complementariamente el peso del color ( $\text{color} = 1 - \text{forma}$ ). Si se aumenta el peso de la información espectral en la segmentación, disminuye el peso de la geometría a la hora de crear los objetos. Si no se da ningún peso al parámetro de forma, los segmentos resultantes pueden tener estructuras fractales y aproximarse poco a la realidad. El parámetro de forma debe aumentarse según lo hace el grado de antropización del área de estudio (Álvarez, 2005). Se ha considerado que en la zona de estudio es adecuado darle un mayor peso a las características espectrales que a las geométricas.

*Suavidad y Compacidad:* La suavidad y la compacidad parten del parámetro de forma. La compacidad optimiza los objetos buscando que sus bordes sean compactos. La suma de los subcriterios suavidad y compacidad es 1. Salvo que se conozca que en el área de estudio un tipo de objetos (suavizado/compacto) es el dominante, se recomienda asignar valores intermedios a estos subcriterios, tal y como se ha hecho en este trabajo.

Con lo mencionado anteriormente, los parámetros utilizados para la segmentación y su posterior aplicación en la clasificación basada en objetos dependen en gran medida de un análisis de prueba-error que depende finalmente de la experiencia y conocimiento que tenga la persona del área de estudio y de los objetos que desee clasificar, lo que dará una combinación acertada de los parámetros y finalmente de la segmentación.

**Fase de asignación y clasificación.-** Una vez realizada la segmentación de los 47428 objetos detectados se exportaron a formato .shp de ArcGis v. 10.1 donde se procedió a clasificar manualmente estos segmentos considerando los mismos ROIs o campos de entrenamientos definidos en la Clasificación basada en píxeles. Para ello se agruparon los objetos en cada una de las 8 clases temáticas definidas en la leyenda.

Luego de seleccionar en ArcGis los objetos que componían las áreas de entrenamiento, se exportó a un fichero GEOTIFF para poder usarlos directamente como muestras en el entorno eCognition.

Para la clasificación se empleó el algoritmo de mínima distancia o vecino más próximo (*Nearest Neighbour*) implementado en el software eCognition. Se eligieron las muestras de objetos seleccionados en entorno ArcGis para cada una de las clases y se clasificó el resto de la escena. El Nearest Neighbor (NN), es un algoritmo no paramétrico de clasificación basado en el muestreo. Este algoritmo se utiliza en base a muestras definidas por el usuario y en combinación con conjuntos de características predefinidas para asignar objetos a las clases. Los datos de entrada utilizadas para el clasificador NN en el presente estudio fueron la media de las bandas R, G, B, RedEdge, NIR, NDVIb5b3 y NDVIb4b3. Se recomienda el uso del clasificador NN cuando es necesario utilizar una compleja combinación de características de un objeto. El principio es simple, en primer lugar el software necesita muestras representativas típicas de cada clase. En base a estas muestras, el algoritmo busca los objetos más cercanos a la muestra y evalúa su valor de pertenencia dentro del espacio de características de cada uno de los objetos (Ferrón, 2011).

## 5.6 Evaluación de la exactitud o validación

La evaluación de la exactitud es un término general para comparar la clasificación con información geográfica que se asume verdadera, con el fin de determinar la veracidad del proceso de clasificación (Perea, 2009).

La validación de la clasificación se ha realizado mediante el muestreo al azar simple. Chuvieco (2010) recomienda un mínimo de 50 píxeles por cada clase temática para obtener una estimación fiable del error, criterio que ha sido seguido en este trabajo, pudiendo esta cantidad ajustarse basándose en la importancia relativa de la categoría y la variabilidad interna de cada categoría (Congalton y Green, 1999). La localización de los píxeles de validación se llevó a cabo a partir de la información tomada en campo así como del análisis visual de la propia imagen.

Para realizar la validación de los dos métodos de clasificación, se realizó mediante el muestreo al azar simple. Se generaron 50 muestras por cada categoría.

Debido a que muchos estudios de OBIA siguen validando sus clasificaciones con las tradicionales matrices de confusión (Congalton y Green, 1999) utilizadas en las clasificaciones basadas en píxeles, en el presente estudio se consideró esta matriz para analizar los dos métodos de clasificación. Particularmente el resultado OBIA se exportó al software Envi para calcular la matriz de confusión utilizando las mismas áreas de validación utilizadas para la validación de la clasificación temática basada en píxeles. El análisis de la matriz de confusión se basó principalmente en la *Fiabilidad global (FG)* de la clasificación, la cual indica el porcentaje total de píxeles clasificados correctamente en la imagen, este índice de fiabilidad ofrece una idea general de la exactitud de la clasificación de las imágenes, si bien no aporta ningún dato sobre la precisión obtenida en cada una de las

clases. Para obtener información de la fiabilidad de cada una de las categorías, es necesario realizar un análisis de los elementos marginales de la matriz de confusión. La *Fiabilidad del Productor (FP)* está relacionada con los marginales en columnas. Indican el número de píxeles que, perteneciendo a una categoría determinada, no fueron incluidos en ella. Se conocen como errores de omisión. Por su parte, los marginales en filas indican la *Fiabilidad del Usuario (FU)* inversamente relacionada con los errores de comisiones, píxeles que se incluyeron en una determinada categoría perteneciendo realmente a otra. En el presente estudio no se calculó el coeficiente Kappa (K) siguiendo las recomendaciones de Pontius (2011), que propone abandonar el uso de Kappa en el análisis de la fiabilidad de la clasificación y utilizar en su lugar dos parámetros: *la cantidad de desacuerdo y el desacuerdo de asignación*, que resultan mucho más simples y útiles para la gran mayoría de aplicaciones.

## 6. RESULTADOS Y DISCUSIÓN

### 6.1 Fase de entrenamiento

En el presente estudio para la clasificación MVS, se ha obtenido un total de 5371 píxeles, distribuidos por toda el área de estudio y en diferentes cantidades como se muestra en la siguiente tabla 2.

Tabla 2. Numero de áreas de entrenamiento en píxeles por categoría

	ROI Name	Color	Pixels	Polygons	Polylines	Points	Fill	Orien	Space
*	Agua	Blue	1.664	0/0	0/0	1.664	Solid	45	0.10
	Páramo	Maroon	774	0/0	0/0	774	Solid	45	0.10
	Matorral arbustivo	Yellow	1.118	0/0	0/0	1.118	Solid	45	0.10
	Pastizal en buenas condiciones	Purple1	433	0/0	0/0	433	Solid	45	0.10
	Pastizal degradado	Red	262	0/0	0/0	262	Solid	45	0.10
	Bosque denso	Magenta	440	0/0	0/0	440	Solid	45	0.10
	Suelo desnudo o terreno en barbecho	White	322	0/0	0/0	322	Solid	45	0.10
	Red vial	Cyan3	358	0/0	0/0	358	Solid	45	0.10

Al igual que para la clasificación MVS, para OBIA se han obtenido como muestras un total 415 objetos, distribuidos en diferentes cantidades para cada clase como se muestra en la tabla y en un ejemplo en la figura 3.

Tabla 3. Cantidad de objetos por categoría temática

Sample Selection Information					
Class	Membership	Minimum Dist.	Mean Dist.	Critical Samples	Number of Samples
Agua	0.996	0.019	2.885		32
Paramo	0.465	3.328	5.190	0	43
Suelo desnudo o en barbecho	0.327	4.865	20.544	0	46
Matorral arbustivo	0.299	5.244	10.800	0	77
Bosque denso	0.223	6.527	9.716	0	21
Red vial	0.074	11.346	37.524	0	131
Pasto degradado	0.051	12.981	22.233	0	39
Pasto en buenas condiciones	0.030	15.183	28.885	0	58

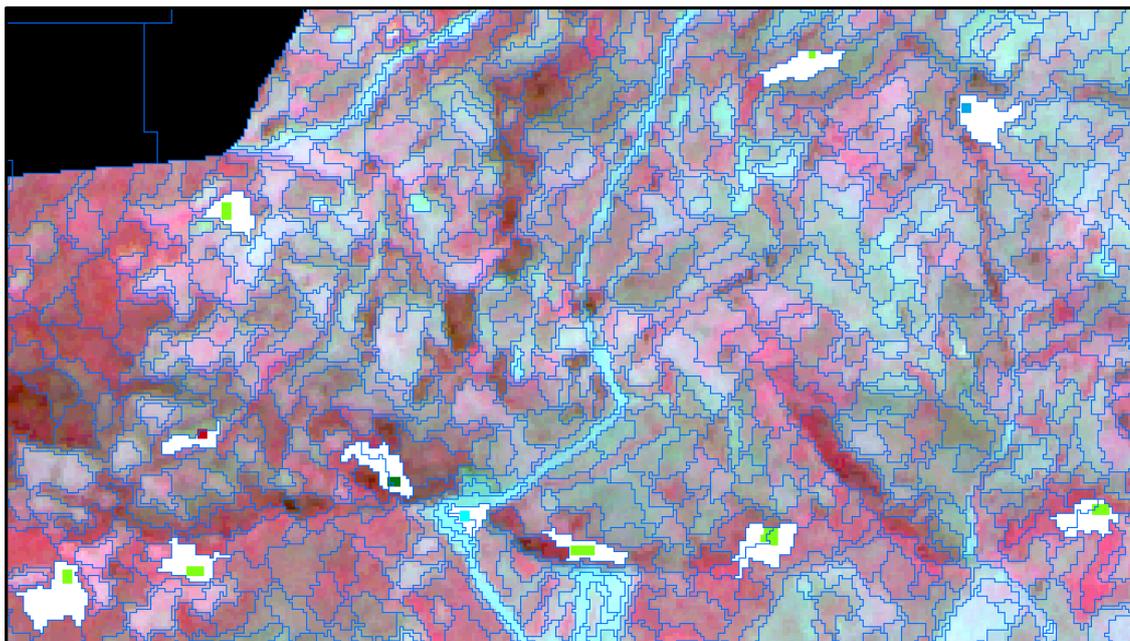


Fig. 3. Distribución espacial de objetos y píxeles en la imagen RapidEye

Como ya se ha comentado, la separabilidad espectral de los campos de entrenamiento seleccionados para la clasificación basada en píxeles se realizó mediante el análisis de la *divergencia transformada* (DT). Los resultados obtenidos se resumen en la tabla 4.

Tabla 4. matriz de separabilidad según la DT de las áreas de entrenamiento definidas en la imagen RapidEye.

NOMBRE	Agua	Páramo	Matorral arbustivo	Pastizal en buenas condiciones	Pastizal degradado	Bosque denso	Suelo desnudo o terreno en barbecho
Agua	--						
Páramo	2,00000000	--					
Matorral arbustivo	2,00000000	1,99907487	--				
Pastizal en buenas condiciones	2,00000000	2,00000000	1,94196687	--			
Pastizal degradado	2,00000000	1,99888995	1,99021937	1,99044212	--		
Bosque denso	2,00000000	1,99999985	1,90567882	1,99816409	1,99999300	--	
Suelo desnudo o terreno en barbecho	1,99999976	1,93765772	1,99999996	2,00000000	1,94899795	2,00000000	--
Red vial	1,99998567	1,99916547	2,00000000	2,00000000	1,99968111	2,00000000	1,96884181

Por un lado se remarcaron con color verde las parejas de clases que tendrían la máxima separabilidad, y con color rojo la de menor separabilidad. Así se pueden observar dos a dos cuales son las clases que probablemente producirán mayor exactitud en la clasificación.

Si calculamos los sumatorios de todas las separabilidades obtenidas entre cada clase y el resto de clases y posteriormente ordenamos dichos sumatorios, obtendremos cuáles son las clases con mayor y menor separabilidad total con respecto a las restantes (tabla 4).

Tabla 5. Orden de separabilidad según la DT

Clase	$\Sigma$ DT
Agua	13,99998543
Red vial	13,96767406
Páramo	13,93478786
Pasto en buenas condiciones	13,93057308
Pasto degradado	13,92822350
Bosque denso	13,90383576
Suelo desnudo o en barbecho	13,85549720
Matorral arbustivo	13,83693989

Como se puede observar en la Tabla 5, la clase que ofreció mayor separabilidad espectral con el resto de cubiertas fue el agua seguida de la red vial. En definitiva se obtuvo una separabilidad promedio de 1,988527085 que resulta ser adecuada, teniendo en cuenta que valores por debajo de 1,7000 indican una pobre separabilidad; entre 1,900 y 2,0000, una separabilidad adecuada, y 2,0000 una separabilidad idónea (Jensen, 2005). La mínima separabilidad obtuvo entre las categorías bosque denso y matorral arbustivo (1,90567882).

Esta baja separabilidad obtenida entre *matorral arbustivo* frente a *bosque denso* y por consiguiente una confusión entre estas dos categorías, puede ser debido a que son cubiertas muy similares y por lo tanto su reflectividad parecida, también puede deberse su confusión a su incorrecta delimitación de las áreas de entrenamiento por la propia heterogeneidad de especies a lo largo de toda la imagen.

## 6.2 Segmentación

La Figura 4 muestra un ejemplo del resultado de segmentar la imagen RapidEye empleando los valores descritos anteriormente. La segmentación completa de la imagen generó 47428 objetos.

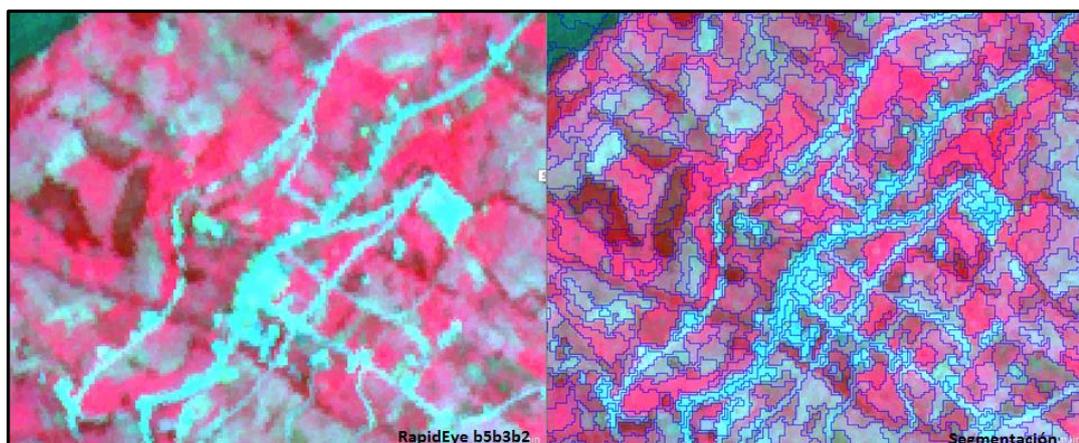
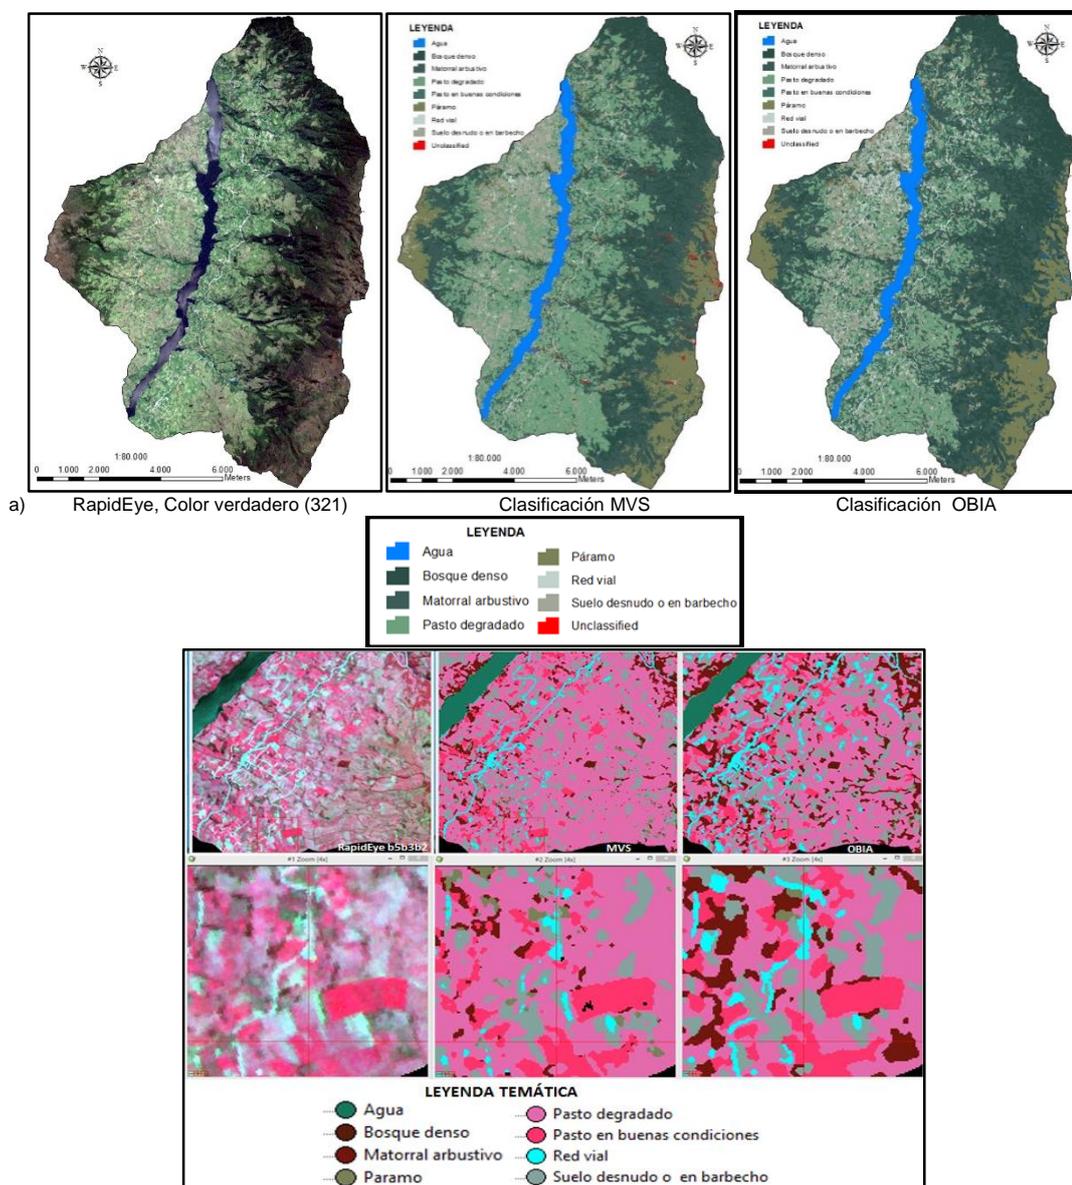


Fig. 4. Imagen RapidEye en falso color (Izq.) y un ejemplo de segmentación empleando el parámetro escala 10, criterio de forma 0.2 y compacidad 0.5 (D.)

Como se ha mencionado anteriormente en OBIA, de la segmentación depende la calidad de su clasificación, por lo que una adecuada selección de los parámetros para segmentar nos daría una buena representación de los objetos de la realidad.

**6.3. Resultados de las clasificaciones de uso y cobertura suelo basadas en píxeles y en objetos de la imagen RapidEye.**

En la figura 5 se pueden observar los resultados obtenidos de la clasificación supervisada mediante píxeles y objetos para la imagen RapidEye, donde se puede apreciar las clases de uso y cobertura, su área, forma y la diferencia entre ambos métodos.



b) Clasificación digital de la Imagen Rapideye (Izq.), por el método MVS (C.) y OBIA (Dere.), representados a diferentes escalas.

Fig. 5.- Representación gráfica de las áreas obtenidas de la clasificación basada en píxeles y en objetos de la imagen RapidEye en color verdadero de toda el área de estudio (a) y en falso color a diferentes escalas (b).

Visualmente se tiene una delimitación coherente de las clases para los dos métodos, sin embargo al ser la imagen del centro (fig. 4,b) una clasificación por píxeles (MVS) se obtuvieron píxeles aislados dentro de las diferentes coberturas por lo que los polígonos correspondientes a cada cubierta son menos compactos.

La Tabla 6 muestra el área ocupada por cada clase definida en la leyenda, tras realizar la clasificación supervisada de la imagen RapidEye, basada en píxeles y mediante objetos. Además se muestra el promedio tanto en hectáreas como en porcentaje del área obtenida según las dos clasificaciones.

Tabla 6. Superficie ocupada por cada clase de cubierta/uso a partir de la clasificación basada en píxeles y en objetos de la imagen RapidEye.

Categorías de cubierta/uso	Clasificación basada en píxeles	Clasificación basada en Objetos	Promedio	Promedio
	Área (ha)	Área (ha)	Área (%)	Área (ha)
Agua	417,02	435,35	4,38%	426,19
Bosque denso	933,45	1424,66	12,13%	1179,06
Matorral arbustivo	2880,58	3254,53	31,55%	3067,56
Páramo	1177,44	995,02	11,17%	1086,23
Pasto degradado	2774,56	1793,21	23,49%	2283,88
Pasto en buenas condiciones	243,89	350,07	3,05%	296,98
Red vial	152,17	372,84	2,70%	262,50
Suelo desnudo o terreno en barbecho	1100,31	1095,62	11,29%	1097,97
Unclassified	41,89	0,03	0,22%	20,96
<b>TOTAL</b>	<b>9721,33</b>	<b>9721,33</b>	<b>100,00%</b>	<b>9721,33</b>

En la siguiente figura 6 se puede observar gráficamente la comparación de áreas en porcentaje de la clasificación basada en píxeles y en objetos de la imagen RapidEye.

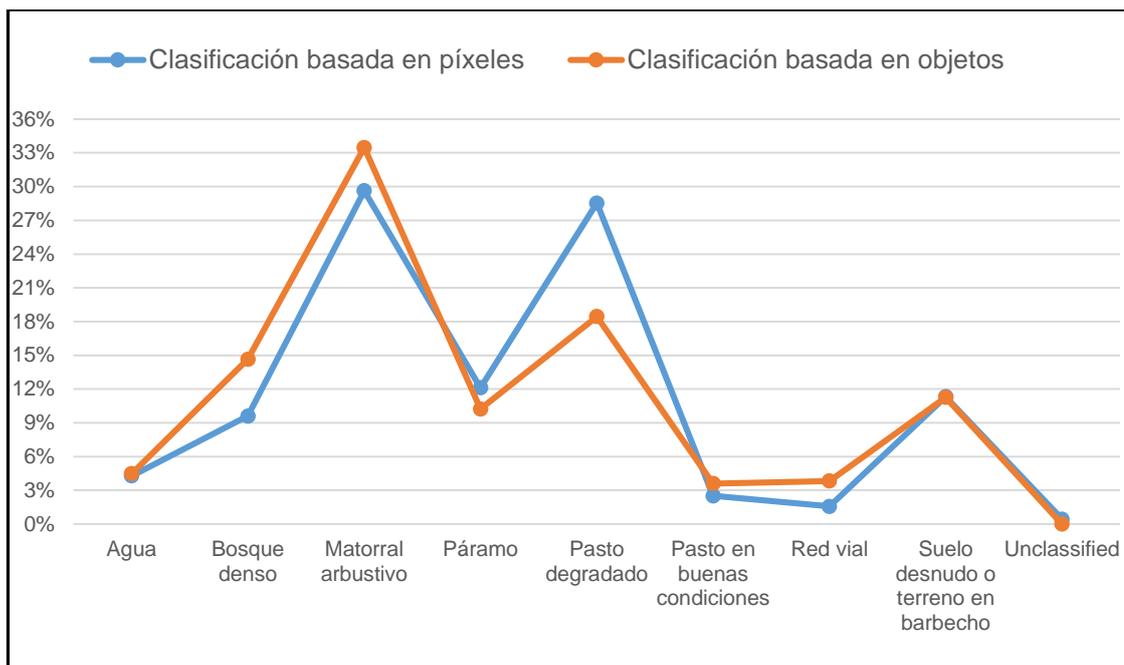


Fig. 6. Representación gráfica de los resultados de las áreas en porcentaje de las clasificaciones basadas en píxeles y en objetos de la imagen RapidEye.

Como se puede ver en la tabla 6 y figura 6, se encontró que la mayor superficie en ambas clasificaciones corresponde a la categoría “Matorral arbustivo” con un promedio de 31,55% equivalente a 3067,56 ha, las demás clases se encontraron en porcentajes promedios inferiores al 24%, siendo del 23,49% para el pasto degradado, entre el 11 y el 12% para el bosque denso, páramo y suelo desnudo o terreno en barbecho ; 4,38% para el Agua, 3,05% para el pasto en buenas condiciones y finalmente de 2,70% para la red vial. Con porcentajes inferiores al 1% aparecen algunas zonas de la imagen que no han sido clasificadas por los diferentes métodos.

La existencia de grandes áreas del “matorral arbustivo” (ocupando un porcentaje elevado de la superficie), seguido por “pasto degradado”, “bosque denso” y “páramo”, refleja la realidad del territorio, que por sus características naturales presenta en el área de estudio un Área de Bosque y Vegetación Protectora (ABVP), destinado a la conservación de los recursos naturales, fundamentales para el funcionamiento biológico, hídrico y en general como el sostén de las comunidades asentadas en la zona de estudio. En la parte alta del área de estudio presenta el ecosistema páramo, en la parte media y baja vegetación densa húmeda interandina, que presentan características adecuadas para el desarrollo y diversificación de actividades productivas, sostenidas por los aportes hídricos de páramo o ecosistemas de alta montaña (PDOT Sevilla, 2012).

La comparación entre clasificaciones revela que la cubierta pasto degradado presenta las mayores diferencias con una superficie muy superior (en torno al 10 %) en el caso de la clasificación OBIA. En cambio las cubiertas de agua y suelo desnudo son las que presentan mayor similitud en cuanto a la superficie cartografiada por ambos métodos.

## 7. VALIDACIÓN

Como se ha mencionado en los apartados anteriores, la determinación de la exactitud de la clasificación se realizó mediante la comparación del resultado de las clasificaciones y la realidad del terreno a través de la matriz de confusión. A continuación se presenta el resultado de la matriz de confusión para los dos métodos de clasificación, la basada en píxeles y en objetos (tablas 7 y 8).

Tabla 7. Matriz de confusión de la clasificación basada en píxeles

		Referencia								Total	Fiabilidad del usuario (%)	Error de comisión (%)
		Agua	Páramo	Matorral arbustivo	Pasto en buenas condiciones	Pasto degradado	Bosque denso	Suelo desnudo o en barbecho	Red vial			
Clasificación	No clasificado	18	10	4	6				1	39		
	Agua	5046								5046	100,00	0,00
	Páramo	1	1125	40			1	40		1207	93,21	6,79
	Matorral arbustivo	2		607	50		997			1656	36,65	63,35
	Pasto en buenas condiciones			9	1044	14				1067	97,84	2,16
	Pasto degradado		5	17	106	693		67		888	78,04	21,96
	Bosque denso			5			489			494	98,99	1,01
	Suelo desnudo o en barbecho		134					729	63	926	78,73	21,27
	Red vial		19					72	596	687	86,75	13,25
	Total	5067	1293	682	1206	707	1487	908	660	12010		
	Fiabilidad del productor (%)	99,59	87,01	89,00	86,57	98,02	32,89	80,29	90,30			
	Error de omisión (%)	0,41	12,99	11,00	13,43	1,98	67,11	19,71	9,70			

**Fiabilidad Global 86,00%**

Tabla 8. Matriz de confusión de la clasificación basada en objetos.

		Referencia								Total	Fiabilidad del usuario (%)	Error de comisión (%)
		Agua	Páramo	Matorral arbustivo	Pasto en buenas condiciones	Pasto degradado	Bosque denso	Suelo desnudo o en barbecho	Red vial			
Clasificación	No clasificado									0		
	Agua	5049								5049	100,00	0,00
	Páramo	8	1266					84		1358	93,23	6,77
	Matorral arbustivo	10	6	666	71	15	788	21		1577	42,23	57,77
	Pasto en buenas condiciones			1	963	36				1000	96,30	3,70
	Pasto degradado				172	599		194	10	975	61,44	38,56
	Bosque denso			14			699			713	98,04	1,96
	Suelo desnudo o en barbecho		21	1		37		460	41	560	82,14	17,86
	Red vial					20		149	609	778	78,28	21,72
	Total	5067	1293	682	1206	707	1487	908	660	12010		
	Fiabilidad del productor (%)	99,64	97,91	97,65	79,85	84,72	47,01	50,66	92,27			
	Error de omisión (%)	0,36	2,09	2,35	20,15	15,28	52,99	49,34	7,73			

**Fiabilidad Global 85,85%**

Como se puede observar en la tabla 7, las categorías que presentan una mayor confusión son el matorral arbustivo y el bosque denso con los mayores errores de comisión y omisión respectivamente. Como ya revelaba el análisis de separabilidad realizado en la fase de entrenamiento, estas dos cubiertas presentan características espectrales muy similares que dificultan su discriminación.

En la tabla 8 también se puede evidenciar la confusión en el matorral arbustivo con el 57,77 % (error de comisión), el bosque denso con el 52,99% (error de omisión), pasto degradado

con el 38,56 (error de comisión) y el suelo desnudo o en barbecho con el 49,34 % (error de omisión).

Tabla 9. Resultado comparativo de la matrices de confusión

Clases	ERROR			
	Omisión (%)		Comisión (%)	
	MVS	OBIA	MVS	OBIA
Agua	0,41	0,36	0,00	0,00
Páramo	12,99	2,09	6,79	6,77
Matorral arbustivo	11,00	2,35	63,35	57,77
Pasto en buenas condiciones	13,43	20,15	2,16	3,70
Pasto degradado	1,98	15,28	21,96	38,56
Bosque denso	67,11	52,99	1,01	1,96
Suelo desnudo o en barbecho	19,71	49,34	21,27	17,86
Red vial	9,70	7,73	13,25	21,72

Fiabilidad Global  
 MVS    OBIA  
 86,00%    85,85%

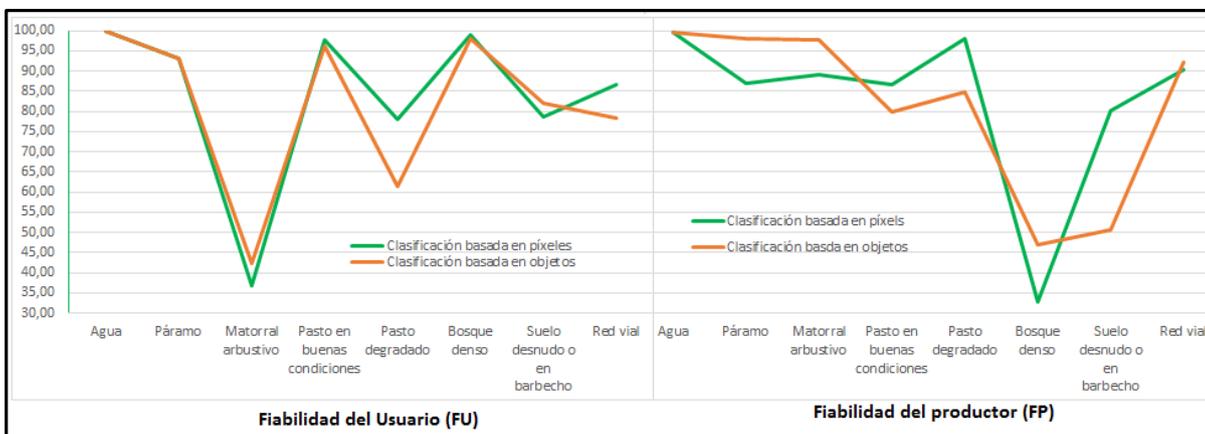


Fig. 7. Resultado comparativo de las fiabilidades obtenidas por los dos métodos de clasificación.

Del análisis comparativo de la matriz de confusión de la tabla 8 y de la figura 7 para los dos métodos de clasificaciones, se obtiene una **fiabilidad global** similar para los dos métodos de clasificaciones del 86% para la Clasificación supervisada basada en píxeles y de 85,85 % para la clasificación OBIA.

Si analizamos en más detalle la **fiabilidad del productor** (errores de omisión) vemos que en algunas categorías como *Bosque denso* y *Suelo desnudo o en barbecho* la clasificación

OBIA presenta una fiabilidad inferior al resto de categorías con errores de omisión en torno al 50%. La clase *Bosque denso* presenta una fiabilidad incluso menor en la clasificación basada en píxeles con un error de omisión del 67,11%, indicando que gran número de píxeles pertenecientes a dicha categoría no se clasificaron como tal, sino en este caso, como *matorral arbustivo*. Sin embargo la categoría *suelo desnudo o en barbecho* aparece mejor clasificada en la clasificación por píxeles que en la clasificación basada en objetos con un error de omisión del 19,71 y 49,34% respectivamente. En este caso las mayores confusiones se producen con las categorías *pasto degradado* y *red vial*.

Por otra parte, la **fiabilidad del usuario (errores de comisión)** nos indica la precisión en la definición de cada categoría. Las fiabilidades obtenidas, tanto por el método MVS como por OBIA, son bastantes satisfactorias en tres de las ocho categorías (páramo, pasto en buenas condiciones y bosque denso) con errores de comisión inferiores al 7 % en ambas clasificaciones. Sin embargo en la clasificación OBIA, en el caso de la clase *Pasto degradado*, el error de comisión es del 38,56% confundiendo con el *suelo desnudo o terreno en barbecho*. El error de comisión también es significativo en la clase *Red Vial* con un 21,72% ya que hay confusión con *suelo desnudo o terreno en barbecho*. En la clasificación de MVS, las clases que presentan un error de comisión más elevado son *el pasto degradado* y *el suelo desnudo en barbecho* con un 21,96 % y 21,97 %, que se confunden con *pasto en buenas condiciones* y *páramo* respectivamente. Sin duda, en los dos métodos de clasificaciones, la clase que presenta el mayor error de comisión, del 57,77% en OBIA y 63,35 % en MVS, es el *Matorral arbustivo* que se confunde muchas veces con el *Bosque denso*.

En resumen, se puede decir que la fiabilidad del productor para 4 de las 8 categorías, es bastante alta para los dos métodos de clasificación, con un 98.8 % para la clasificación basada en píxeles frente a un 96,87% la basada en Objetos, que indican que 98 y 97 respectivamente de cada 100 píxeles pertenecientes a esta cubierta fueron discriminados adecuadamente en la clasificación. Como posibles causas a la confusión del ***matorral arbustivo***, sobre todo frente a ***bosque denso***, estaría relacionado a las características espectrales similares de ambas cubiertas debido a que tanto el matorral arbustivo como el bosque denso presentan un grado de madurez similar, por consiguiente existe una confusión por la separabilidad espectral de las cubiertas .

Es importante en este sentido resaltar que la clasificación OBIA mejora ligeramente la clasificación de estas cubiertas (*matorral arbustivo* y *bosque denso*), y presenta errores de omisión y comisión más bajos en general, mientras que su calificación es peor que la de píxeles en el *pasto degradado* porque presenta mayores errores de omisión y comisión

Para el resto de categorías de la leyenda de trabajo, la fiabilidad obtenida se puede considerar buena, ya que tanto la exactitud del productor como del usuario son >78% en la clasificación basada en píxeles y, moderada en la clasificación basada en Objetos que son >50%.

## 8. CONCLUSIONES Y RECOMENDACIONES

Al finalizar el proyecto de tesis se logró evaluar y contrastar los dos métodos de clasificación: basado en píxeles y en objetos (OBIA), alcanzando de esta forma el objetivo principal planteados en el tema de proyecto de grado, de evaluar métodos novedosos y apropiados para obtener información sobre el uso y cobertura del suelo en Ecuador a partir de imágenes de muy alta resolución espacial.

En ambas clasificaciones la mayor confusión se produce por asignación de píxeles a la categoría *Matorral arbustivo* que presenta una elevada confusión con la categoría *Bosque denso*. Sin embargo, la clasificación OBIA presenta, para esta categoría, un porcentaje de error de comisión 5,6 puntos inferior frente a la clasificación basada en píxeles.

Se recomienda que no exista mucho desfase entre la fecha de toma de una imagen satelital y las salidas de campo para minimizar el riesgo de cometer errores de interpretación.

Se sugiere ampliar este trabajo con el uso de texturas y de variables de contexto mediante la aplicación de conjuntos de reglas que presenta el software eCognition.

Los resultados obtenidos en este estudio muestran que la clasificación basada en objetos, muestra algunas mejoras puntuales respecto a la clasificación basada en píxeles. Sin embargo, al ser una metodología novedosa, se requiere un mayor conocimiento y experiencia para explotar todo su potencial. No obstante consideramos que es una técnica de gran interés para extraer información temática a partir de imágenes de muy alta resolución espacial tal y como han demostrado numerosos estudios y proyectos realizados hasta el momento.

## 9. REFERENCIAS BIBLIOGRÁFICAS

- ✓ Abkar, A. A., Sharifi, M. A., Mulder, N. J. (2000). Likelihood-based image segmentation and classification: a framework for the integration of expert knowledge in image classification procedures. *International Journal of Applied Earth Observation and Geoinformation*. 2:104-119.
- ✓ Álvarez, F. (2005). Remote sensing and Geoinformation Systems applied to the forest management of *Eucalyptus globulus* Labill. Stands damaged by *Gonipterus scutellatus* Gyllenhal in Galicia. [Tesis Doctoral]. Departamento de ingeniería de los recursos naturales y medio ambiente. Universidad de Vigo, 319 p.
- ✓ Ardila, J. P., Espejo, O. J., Herrera, J. L. (2005). Validación de una Metodología de Clasificación de Imágenes Satelitales en un Entorno Orientado a Objetos. *Universidad Distrital Francisco José de Caldas, Facultad de Ingeniería*, v.10, n.1, p. 61-69.
- ✓ Castillejo, I. (2011). Evaluación de métodos basados en píxeles y objetos para la clasificación de usos de suelo con imágenes de satélite Quickbird, para el seguimiento de medidas agroambientales y la optimización del uso de herbicidas con agricultura de precisión. (TESIS DOCTORAL). Departamento de Ingeniería Gráfica y Geomática. Universidad de Córdoba.
- ✓ Baatz, M., Schäpe, A. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: *Proceedings of the 12th Symposium for Applied Geographic Information Processing (Angewandte Geographische Informationsverarbeitung XII. AGIT 2000)*, Salzburg, Austria, pp. 12-23.
- ✓ Benz, U., Hofman, P., Willhauck, G., Lingenfelder, I., Heynen, M., (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *Photogram. Eng. Rem. Sens.* 58: 239-258.
- ✓ CELEC EP- Hidropaute. (2012). Informe Anual.
- ✓ Chuvieco, E. (2010). *Teledetección Ambiental*. Tercera Edición, Ediciones Ariel, Barcelona, España. 591 pp.
- ✓ Congalton, R.G. (1991). A review of assessing the accuracy of classification of remotely sensed data. *Remote Sensing of Environment* 37, 35-46.
- ✓ CGPaute (2011). Programas de acción forestal para las subcuencas del collay, mazar, pindilig, paute y magdalena.
- ✓ Ferrón, R. V. (2011). Optimización de la clasificación supervisada en objetos aplicada a ambientes rurales a partir de ortoimágenes de Geoeye-1.
- ✓ García, T. J., Mas, J. F. (2008). Comparación de metodologías para el mapeo de la cobertura y uso del suelo en el sureste de México. *Investigaciones geográficas* 67. p. 7-19.
- ✓ Gong, P., Howarth, P.J. (1990). The use of structural information for improving spatial resolution and classification accuracy land-cover classification accuracies at the rural-urban fringe, *Photogrammetric Engineering and Remote Sensing*, 56, 67- 73.
- ✓ Hay, G.J., Castilla, G. (2006). Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT), In *Proceedings of 1st International Conference on Object-based Image Analysis – OBIA*. (2006), Salzburg University, Austria, July 4-5, 2006. Vol. XXXVI, ISSN 1682-1777.

- ✓ Haboudane, D., et al. (2004) Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. *Rem. Sens. Env.* 90: 337-352.
- ✓ Jensen, J.R. (2005). *Introductory digital image processing: a remote sensing perspective*. Series in geographic information science. Pearson Prentice Hall, South California. 526 p. Jinlong, F., W. Bingfang and
- ✓ JENSEN, J. (1996). *Introductory digital image processing*. 2<sup>nd</sup> Edition. Ed. Prentice hall, New Jersey, USA. 316 p.
- ✓ Martín F. (2011). Rapideye y la banda Red-Edge, para el modelado de la vegetación y recuperación de la humedad del suelo. *Mapping*, ISSN 1131-9100, N° 150, 2011, págs. 10-21.
- ✓ Maussel, P., Kramber J., Lee, J. (1990). Optimum band selection for supervised classification of multispectral data", *Photogrammetric Engineering and Remote Sensing*, vol. 56, no. 1, pp. 55-60.
- ✓ Mejía, X. A., Moncayo, P. J. (2012). Evaluación de métodos de clasificación de imágenes satelitales de moderada y alta resolución para la obtención de mapas de uso y cobertura del suelo basados en píxeles y orientados a objetos: Estudio de caso en subescena de la parroquia Shushufindi, Provincia de Sucumbíos, utilizando imágenes Aster e Ikonos. Carrera de Ingeniería Geográfica y del Medio Ambiente. ESPE. Sede Sangolquí. <http://repositorio.espe.edu.ec/handle/21000/5528>. (04 de Junio de 2013).
- ✓ Alberto, P. A., Meroño, J., Aguilera, M. (2009). Clasificación orientada a objetos en fotografías aéreas digitales para la discriminación de usos del suelo. Universidad de Córdoba (UCO) España. VOL. 34 N° 9.
- ✓ Pontius, R.G.; Millones, M. (2011). Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32:15, 4407-4429.
- ✓ PDOT, (2011). Plan de Ordenamiento Territorial del cantón Sevilla de Oro.
- ✓ Swain, P.H., Davis, S.M. (1978). *Remote Sensing: The Quantitative Approach*. McGraw Hill, New York.