

ANEXO 1. Imagen SPOT Cuenca Santiviáñez

Segmentación y clasificación de imágenes satelitales para determinar la cobertura del suelo



Lizardo Mauricio Reyna Bowen
Ingeniero Agrícola, graduado en la Facultad de Ingeniería Agrícola Universidad Técnica de Manabí

Maestría en Ciencias de la Geo-información y Observación de la Tierra
Mención en Evaluación de Recursos Hídricos.
Teléfono: 00593-84187545
Email: farlizx@gmail.com
Centro de Levantamiento Aeroespaciales y Aplicaciones SIG (CLAS) UMSS - International Institute for Geoinformation and Earth Observation (ITC, Holanda) Cochabamba-Bolivia, 2010.

Lcdo. Benjamín Gossweiler H. M. Sc.

Centro de Levantamiento Aeroespaciales y Aplicaciones SIG (CLAS) UMSS - International Institute for Geoinformation and Earth Observation (ITC, Holanda)
Teléfono: 00591-44540750
Email: gossweiler@clas.umss.edu.bo
Cochabamba-Bolivia, 2010.

RESUMEN

Desde hace unas décadas se han implementado técnicas espaciales en el estudio de los recursos naturales, la más importante es la clasificación temática de imágenes satelitales para determinar el tipo de cobertura.

Las técnicas convencionales de clasificación no garantizan una cartografía temática exacta, se basan en el análisis a nivel de pixel, los que pueden contener información mezclada en el caso de los pixeles borde, esto conlleva a errores cualitativos (límites) y cuantitativos (áreas y perímetros) en los mapas temáticos.

Se aplicó la metodología de clasificación orientada a objeto a una imagen SPOT de la cuenca Santiviáñez ubicada en Cochabamba-Bolivia. Se realizaron 72 segmentaciones con el módulo Featureextraction de Envi Ex, variando los parámetros scale y merge cada 10 unidades. La evaluación de las segmentaciones se realizó mediante una función objetivo propuesta por (Espindola et al., 2006), basada en la varianza y el índice *de de Moran I*. Se determinó que los parámetros óptimos para la segmentación fueron; para scale→20 y para merge→50.

Se obtuvieron segmentos de entrenamiento para 6 clases, la clasificación se realizó en base a los atributos espectrales y texturales. La evaluación se realizó con zonas de muestreo tomadas sobre la imagen, respaldadas por puntos de control tomados en campo y Google Earth. Con el resultado de la matriz de confusión se calcularon dos indicadores de calidad; la precisión global que llegó a 94.61% y el coeficiente Kappa resultó 0.92.

INTRODUCCIÓN

El mapeo de la cobertura del suelo realizada en forma manual requiere de muchos recursos económicos y resulta muy laborioso el trabajo de campo, la tecnología de percepción remota o teledetección permite identificar los tipos de cobertura del suelo en forma más eficiente y económica, actualmente existen variedad de productos (imágenes) satelitales y aerotransportados que facilitan la clasificación de grandes extensiones de terreno, además resulta significativamente más económico que el método convencional de campo.

El análisis de imágenes orientado a objeto es cada vez más utilizado para la clasificación de imágenes de alta resolución. El primer paso es dividir la imagen en regiones (objetos) y luego clasificarlos en base a sus atributos espectrales y relaciones espaciales (**Liu et al., 2008**).

Un algoritmo de segmentación divide la imagen en regiones relativamente llamados "objetos candidatos", que en futuros procesos serán analizados y transferidos a objetos mayores (**Blaschke, 2010**).

Una reciente investigación sobre biomasa forestal **Kajisa et al(2009)**, demuestra que el análisis orientado a objeto incrementa significativamente el grado de correlación entre los resultados obtenidos de la imágenes y los datos de verdad del terreno respecto al método basado en píxeles, obtuvieron un $R^2 = 0.76$ y 0.67 respectivamente.

OBJETIVOS

OBJETIVO GENERAL

Evaluar la técnica de segmentación de imágenes con fines de clasificación, para determinar la cobertura del suelo.

Objetivos específicos

- Determinar los parámetros óptimos de segmentación mediante una función objetivo.
- Determinar la cobertura del suelo de la cuenca Santiviáñez a través de imágenes SPOT, mediante segmentación.
- Evaluar la clasificación.

METODOLOGÍA

SEGMENTACIÓN DE IMAGEN SPOT

Para la segmentación de la imagen SPOT multiespectral correspondiente a la zona de Santiviáñez del departamento de Cochabamba (Anexo 1), se seleccionó una sección representativa de la imagen de 430×386 píxeles, se utilizó el programa Envi Ex 4.7. Envi Ex utiliza "**edge-based algorithm**" para segmentar las imágenes, requiere solo de un parámetro para ejecutarse "Scalelevel", este parámetro puede variar entre 0 y 100. Valores altos generarán pocos segmentos. Se elegirán valores pequeños si se requiere extraer segmentos bien definidos. Una buena segmentación garantiza una clasificación bastante exacta (ITTVIS, 2009).

Un parámetro opcional es "Mergelevel", tiene un rango de 0 a 100, se utiliza para integrar segmentos muy pequeños a segmentos más grandes, elementos como árboles y nubes pueden generar segmentos no deseados (según sea el caso) por lo que se necesitará unir estos segmentos a los adyacentes.

Se generaron 72 segmentaciones para la imagen SPOT utilizando las 4 bandas, variando el factor escala de 10 a 80 cada 10, y para cada variación se utilizó el factor "Merge" de 0 a 80 cada 10.

EVALUACIÓN DE LA SEGMENTACIÓN

La función objetivo (ecuación 1) se basa en dos criterios; similaridad intra - segmento y disimilaridad inter-segmentos, para ello utiliza la varianza (v) ponderada de cada segmento y el índice de Moran (I), este último utiliza las coordenadas xy para determinar criterio de vecindad. Cuando se trabaja con polígonos se puede adoptar varios criterios de vecindad por ejemplo; dos polígonos serán vecinos si comparten una frontera, o se consideran vecinos si la distancia entre los centroides no supera un valor determinado.

$$F(v, I) = F(v) + F(I)$$

Ecuación 1

Para calcular autocorrelación (ecuación 2) de cada una de las segmentaciones se utilizó el promedio de los números digitales de las 4 bandas de la tabla de atributos de los mapas de centroides de los polígonos, la distancia de peso para el criterio de vecindad fue la que exista 100% de probabilidad de por lo menos a esa distancia se encuentre otro punto, esto se puede obtener mediante un "**pattern análisis**". La varianza ponderada se la obtuvo del promedio de la varianza de las 4 bandas en cada uno de los segmentos.

$$I = \frac{n}{S_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Ecuación 2

Finalmente el valor más alto de la función objetivo, determinó los valores apropiados para factor scale y factor merge para la segmentación.

CLASIFICACIÓN

Ninguna clasificación está completa hasta que su exactitud sea evaluada, (**Brand y Mather, 2009**). Se tomaron puntos de control de terreno de la zona para contrastar los resultados a través de la matriz de confusión, estos puntos sirvieron de referencia para escoger sobre la imagen zonas de control, ya que la imagen utilizada es de varios años anteriores, sin embargo la zona escogida para este estudio no presenta gran actividad humana, por tanto los cambios en la cobertura del suelo no son significativos hasta la presente fecha.

Con la imagen segmentada con los parámetros obtenidos mediante la función objetivo, se clasificó a través de zonas de entrenamiento. Este proceso resulta muy similar a un clasificación supervisada, difiere en que las zonas de muestreo son polígonos (segmentos u objetos) y no píxeles. Se seleccionaron segmentos representativos de cada clase a extraer.

El algoritmo utilizado para clasificar, fue *K Nearest Neighbors* utiliza la distancia euclidiana en un espacio n-dimensional donde n es el número de atributos, y es mucho menos sensible al ruido. El parámetro *K* indica el número de vecinos que serán considerados en la clasificación (**ITTVIS, 2009**).

Clases	
Cultivos	
Urbano	
Zona Boscosa	
Zona sin vegetación	
Roca	
Suelo en descanso	

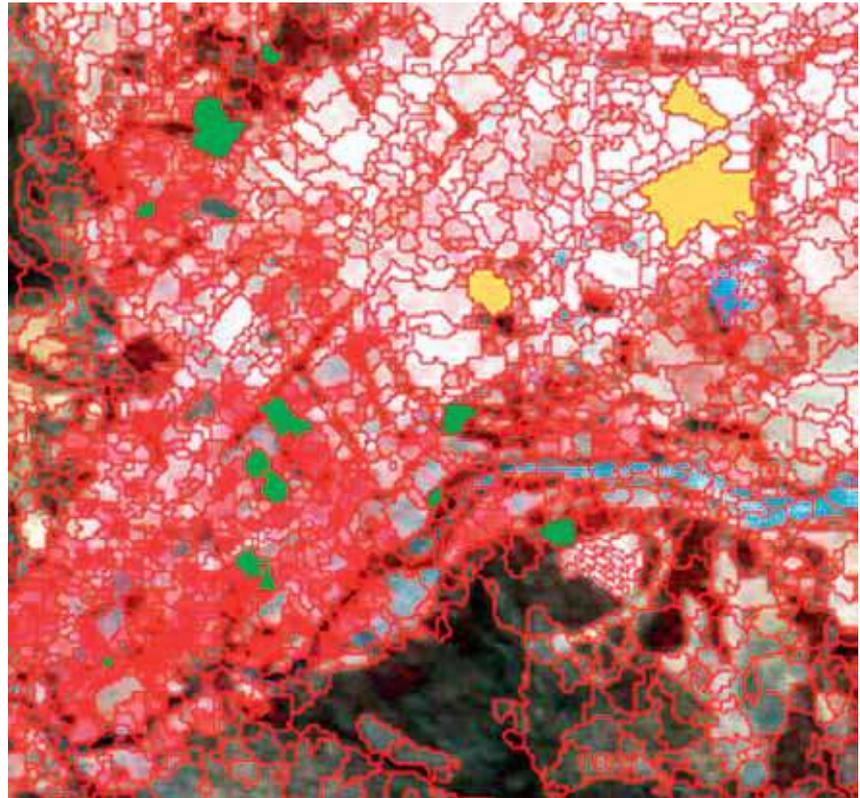


Figura 1. Proceso de entrenamiento para la clasificación

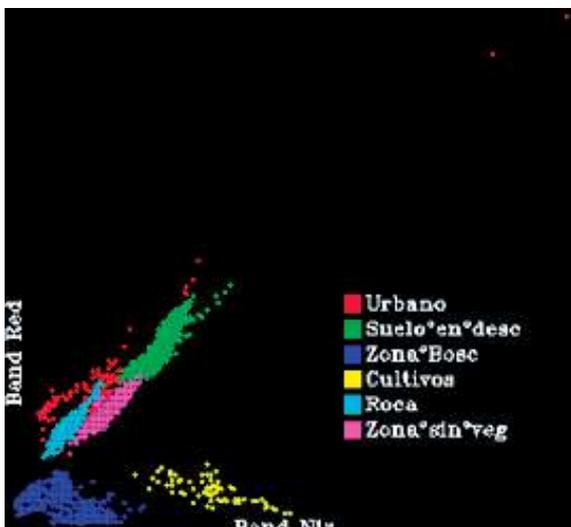


Figura 2. Scatterplot

EVALUACIÓN DE LA CLASIFICACIÓN

Con los puntos GPS de referencia tomados en campo, y con la ayuda de Google Earth, se seleccionaron polígonos de control sobre la imagen de cada una de las clases para evaluar los resultados de la clasificación (**Figura 3**). Se tomaron varias muestras de cultivos distantes a las del entrenamiento, de igual forma para las otras clases, con esto se pretende tener representatividad en las muestras sobre la imagen. Sin duda las zonas urbanas presentaron mayor dificultad, en esta clase se consideraron también las construcciones dispersas en la zona.

Para asegurar la pureza de las muestras para la evaluación, se analizaron mediante un scatterplot. Como se aprecia en la **Figura 2**.

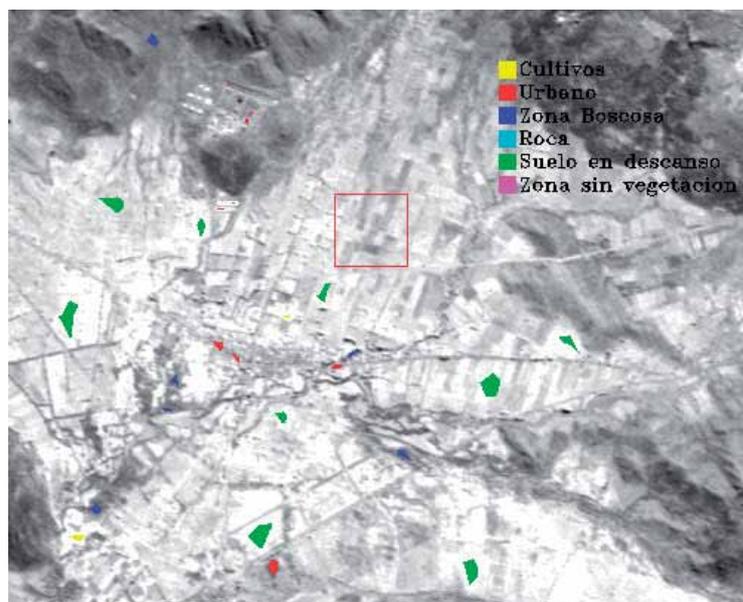


Figura 3. Zonas de muestreo para la evaluación

Se evaluó la precisión mediante dos fuentes; precisión global y el coeficiente Kappa.

$$PG = \frac{\sum_{i=1}^r x_{ij}}{N}$$

Ecuación 3

Donde:

- r = Numero de filas de la matriz
- X_{ji} = Numero de observaciones en la fila i y columna i
- N = Total de puntos muestreados

El estadístico Kappa (κ), mide el grado de ajuste debido solo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios (Esperanza y Zerda, 2010).

$$K = \frac{N \sum_{i=1}^r X_{ij} - \sum_{i=1}^r (X_i + xX + i)}{N^2 - \sum_{i=1}^r (X_i + xX + i)}$$

Ecuación 4

Donde:

- r : es el número de filas en la matriz.
- X_{ij} : número de observaciones en la fila i y columna i .
- X_{i+} : totales marginales de la fila i .
- X_{+i} : totales marginales de la columna i .
- N : número total de píxeles de referencia.

RESULTADOS Y DISCUSIÓN

SEGMENTACIÓN

Se obtuvieron 72 segmentaciones variando los parámetros Scalelevel y Mergelevel. En la segmentación más fina se generaron 14440 segmentos (s1000), mientras que en la más gruesa (s8080) se generaron 217 segmentos, es notorio que el rango de posibilidades es bastante grande, si bien el objetivo de la segmentación es determinante para la elección de los parámetros más apropiados, trabajar con parámetros mayores a 80 resulta improductivo porque existe mucha mezcla de objetos, lo cual se aleja del objetivo de una segmentación. Ahora bien para determinar cuál de tantas posibilidades es la más apropiada para una clasificación temática, se evaluaron cada una de las segmentaciones generadas de acuerdo con la función objetivo, para ello se calculo la varianza ponderada respecto al área en píxeles, y el índice de autocorrelacion de Moran (I), ambos parámetros normalizados (**Tabla 2**).

Parámetro	Varianza Normalizada	I Normalizado	Función Objetivo
Min	1	0.0000	1
1 stQu.	1	0.9024	1.9024
Median	1	0.9422	1.9422
Mean	1	0.8751	1.8751
3 rdQu.	1	0.9612	1.9612
Max	1	1.0000	2

Tabla 1. Estadística resumen del resultado de la función objetivo

Matemáticamente los resultados de la función objetivo son levemente distintos, sin embargo, los parámetros de segmentación pueden variar significativamente entre cada resultado.

Se determinó el valor más alto de la función objetivo, y, a que combinación de parámetros de Scale y Merge correspondía dicho valor, para ello se generó un diagrama de dispersión en 3D (Figura 4), en el cual el eje x (10-80) corresponde al Scalelevel, el eje y(1-2) a la función objetivo, y el eje z (0-80), a Mergelevel,

La opción apropiada de parámetros será la que combine una baja autocorrelación espacial (segmentos adyacentes distintos) y una baja varianza intra-segmentos (Espindola et al., 2006).

Se determinó que los parámetros óptimos para segmentar la imagen SPOT, de acuerdo a la función objetivo son; para Scalelevel \rightarrow 20 y para Mergelevel \rightarrow 50 (Figura 5). La imagen fue segmentada de acuerdo con estos parámetros y el resultado se muestra en las (Figura 6), (Figura 7) y (Figura 8).

Figura 4. Diagrama de dispersión 3D

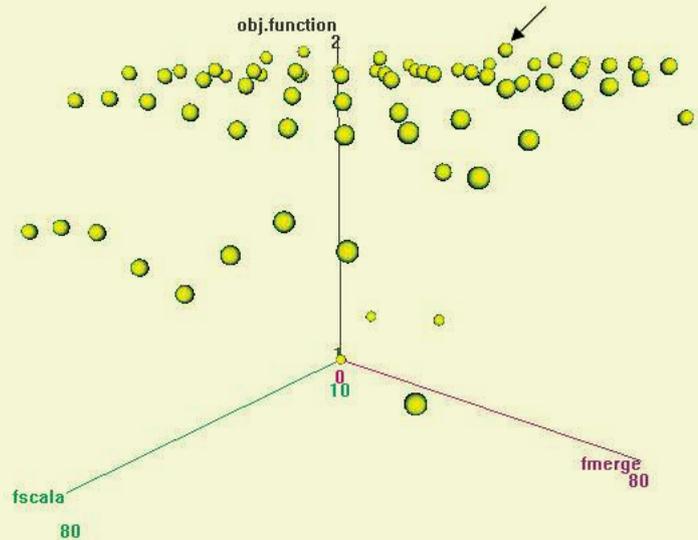


Figura 5. Identificación de los parámetros de entrada

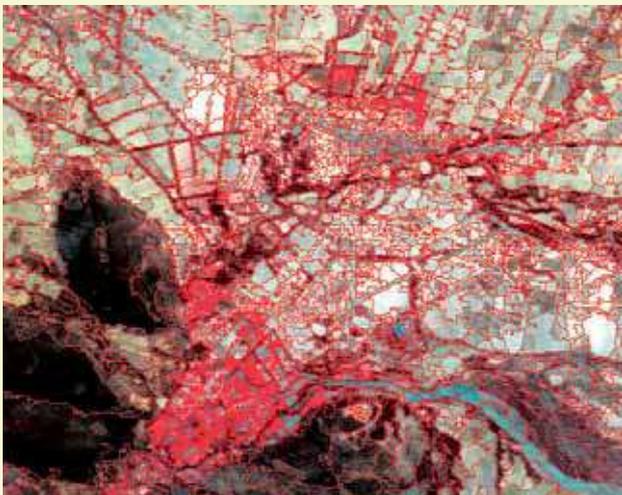
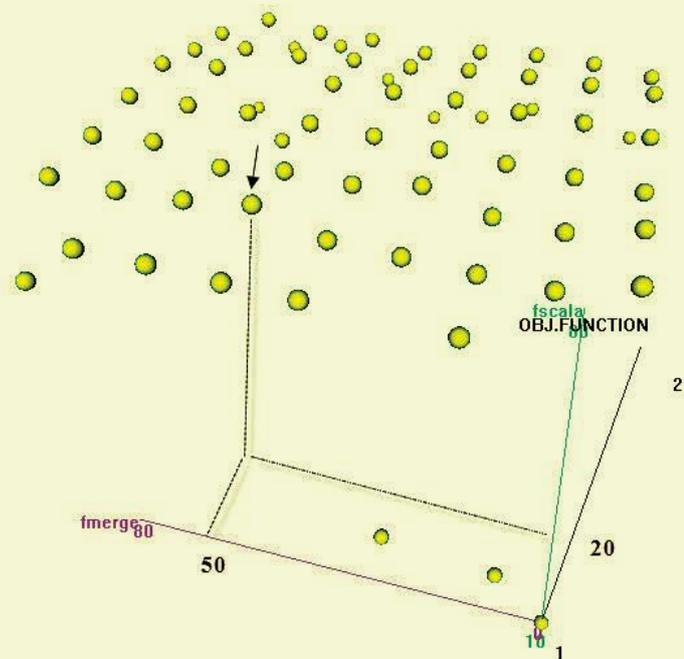


Figura 6. Imagen segmentada

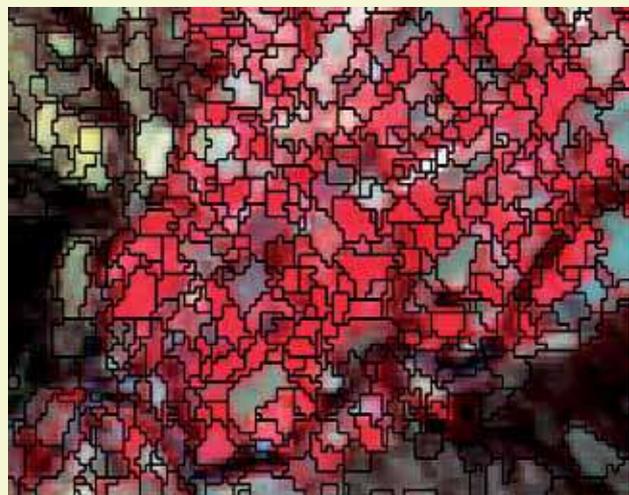


Figura 7. Detalle de la segmentación

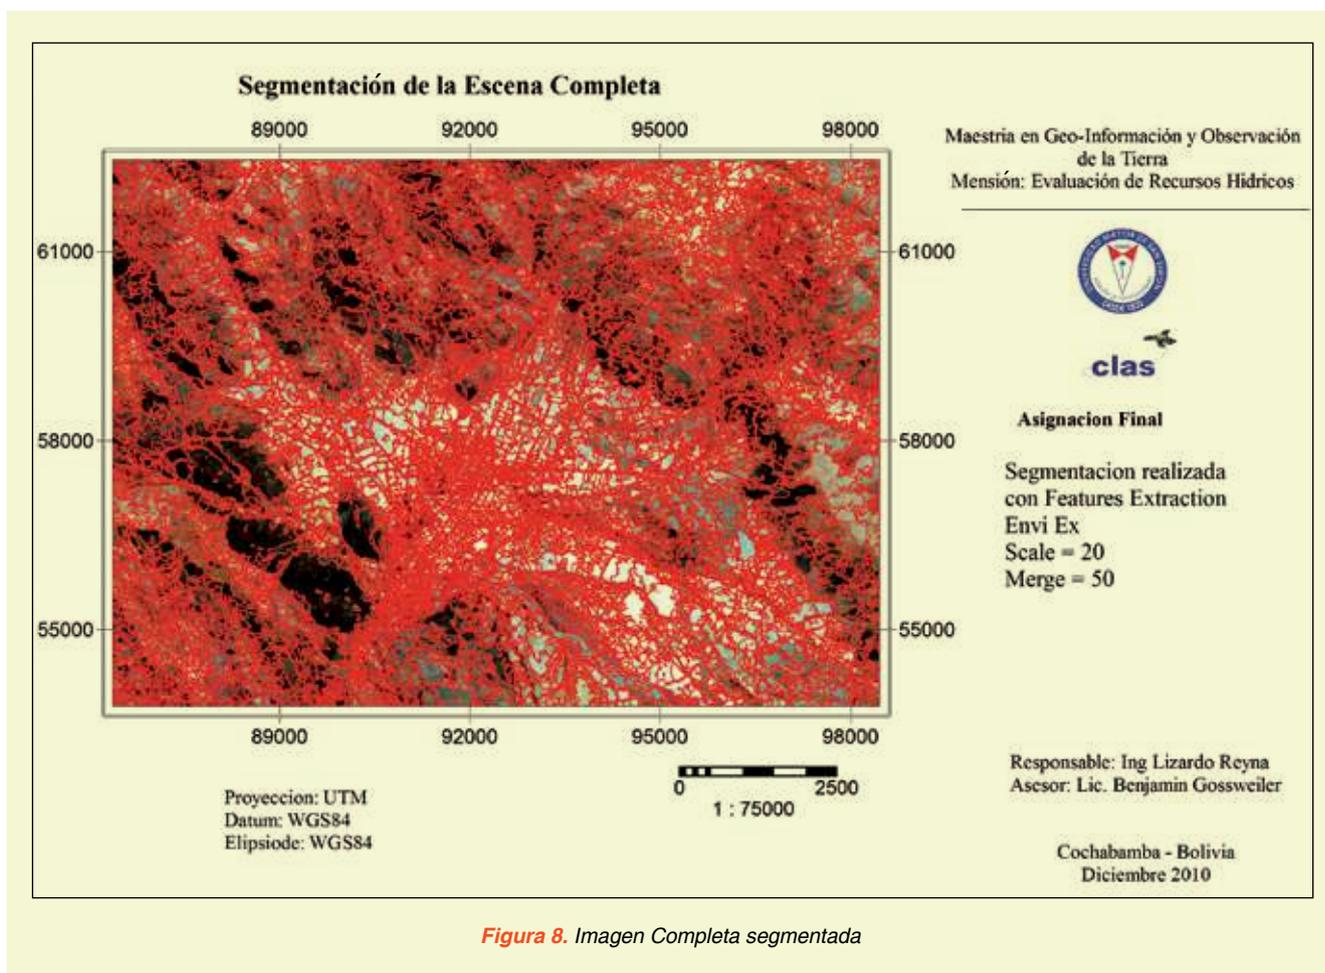


Figura 8. Imagen Completa segmentada

CLASIFICACIÓN

Se clasificó la imagen segmentada mediante el algoritmo K NearestNeighbor (Figura 9), todos los pixeles de la imagen fueron asignados a una clase, por tanto la clasificación resultó exhaustiva, se evaluó mediante la matriz de confusión respecto a las muestras de control tomadas sobre la imagen, los resultados se muestran en las

Clase	Cultivos	Zona_Boscosa	Zona_en_descanso	Urbano	Roca	Zona_sin_vegetacion
Unclassified	0	0	0	0	0	0
Cultivos	80	5	0	0	0	0
Zona_Boscosa	0	491	0	2	0	0
Zona_en_descanso	0	0	1281	1	0	86
Urbano	0	0	0	84	6	0
Roca	0	0	0	47	461	30
Zona_sin_vegetacion	1	0	0	3	4	851
Total	81	496	1281	137	471	967

Tabla 2. Matriz de confusión

Como se advertía en el scatterplot, las zonas urbanas, roca, y zonas sin vegetación, compartían lugares en el espacio característico, lo que significa que existen zonas diferentes, con respuestas espectrales similares. Durante

la clasificación ocurrió que segmentos correspondientes a la clase roca fueron asignados a la clase urbano (47), y segmentos correspondientes a la clase suelo en descanso, fueron asignados a la clase sin vegetación (86).

Precisión Global	94.61%
Coefficiente Kappa (K)	0.92

Tabla 3. Índices de calidad

Un valor K igual a 1 indica un acuerdo pleno entre la realidad y el mapa, mientras un valor cercano a 0, indica que el acuerdo observado es puramente debido al azar.

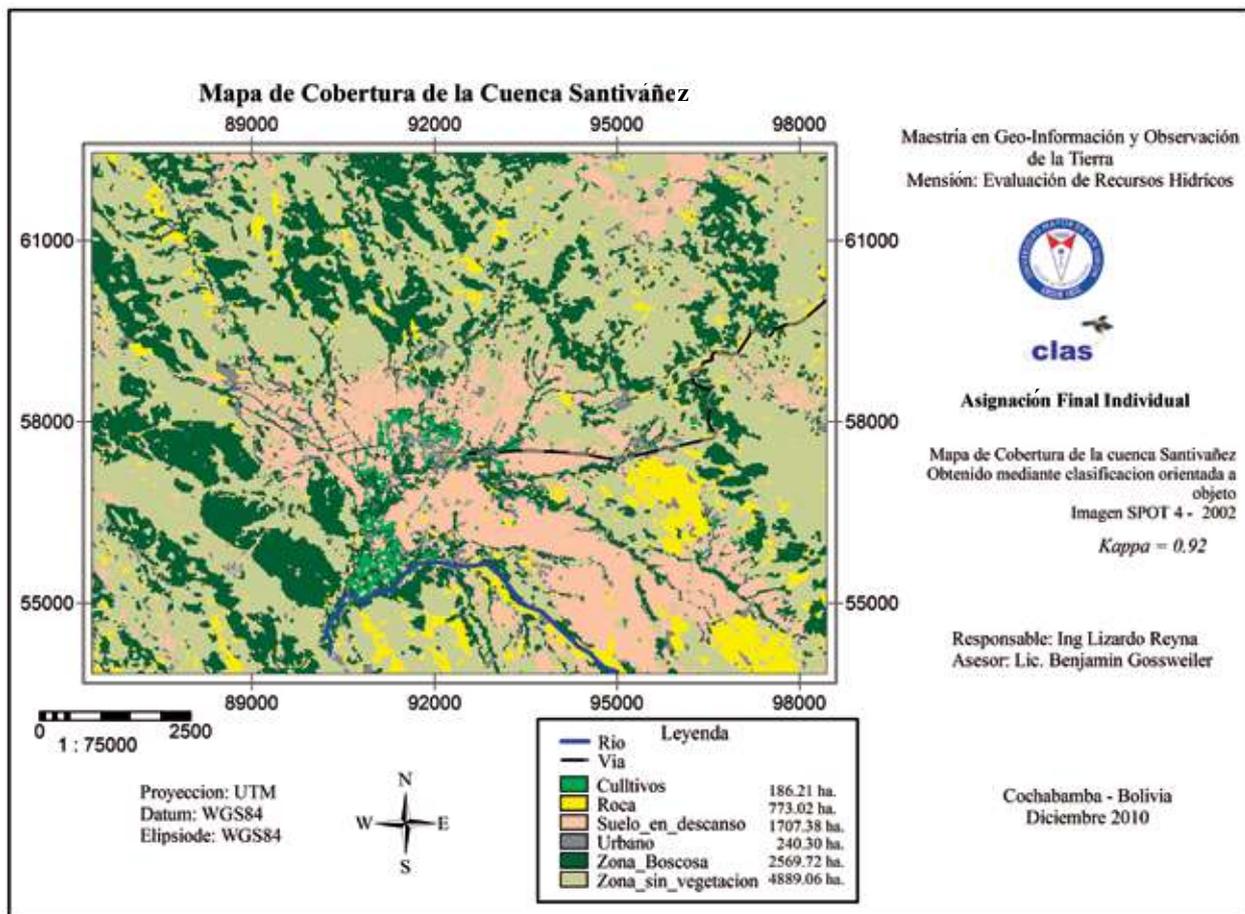


Figura 9. Mapa de cobertura del suelo

CONCLUSIONES

El objetivo de este estudio fue explorar la técnica de segmentación de imágenes a fin de obtener una clasificación temática más exacta que la conseguida con metodología convencional de clasificación, además, desarrollar una manera cuantitativa de controlar la calidad de la segmentación a través de parámetros estadísticos.

El análisis de imágenes orientado a objeto, reduce significativamente el número de elementos a analizar durante la clasificación, optimizando el tiempo de cálculo. El análisis de basado en pixel es reemplazado por el análisis a nivel de segmentos, que están dados por agrupaciones de píxeles con similares características espectrales y texturales. La segmentación requiere que el

usuario establezca ciertos parámetros, esto conlleva a tener múltiples opciones para segmentar una imagen, los segmentos generados contienen atributos de las bandas utilizadas en la segmentación, esto permite trabajar estadísticamente sobre ellos y establecer criterios y condiciones óptimas para el objetivo deseado.

La función objetivo utilizada para evaluar las segmentaciones, permitió establecer los parámetros óptimos para garantizar una buena clasificación, para ello fue necesario realizar muchas pruebas de segmentación ya que los resultados diferían en unas pocas decimas, sin embargo, esas diferencias pueden ser efecto de parámetros de estrada muy diferentes.

BIBLIOGRAFÍA

- BLASCHKE, T. 2010.** Object based image analysis for remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing 65, 16.
- BRAND, T. & MATHER, P. M. 2009.** Classification Methods for Remotely Sensed Data. Taylor & Francis Group.
- ESPERANZA, F. & ZERDA, H. 2010** Clasificación digital de coberturas vegetales a partir de datos satelitales multiespectrales. http://www.inta.gov.ar/manfredi/info/boletines/a_reasuelos/cober_veg_satel_multi.pdf Consultado On Line Diciembre 2010.
- ESPINDOLA, G. M., CAMARA, G., REIS, I. A., BINS, L. S. & MONTEIRO, A. M. 2006.** Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. International Journal of Remote Sensing, 27, 3035 — 3040.
- ITTVIS 2009.** Envi Ex Help. ITT Visual Information Solutions software.
- KAJISA, T., MURAKAMI, T., MIZOUE, N., TOP, N. & YOSHIDA, S. 2009.** Object-based forest biomass estimation using Landsat ETM+ in Kampong Thom Province, Cambodia. The Japanese Forest Society and Springer.
- LIU, Y., GUO, Q. & KELLY, M. 2008.** A framework of region-based spatial relations for non-overlapping features and its application in object based image analysis. ISPRS Journal of Photogrammetry & Remote Sensing 63, 461–475.