

# Land Use and Land Cover in the San Juan Estuary Basin scale 1:50 000

Mauricio R. Morejón Centeno

University of Puerto Rico at Mayaguez, Department Agroambientales Sciences  
Call Box 9000, Mayagüez, PR 00681-9000

**ABSTRACT.-** The classification of land use and land cover to identify and manage resources or elements that make up a digital image. Basin San Juan Estuary is an area of economic, tourist and ecological importance and it is necessary to know the elements composing. The objectives of this research were: a) Perform land use and land cover current Estuary Basin of San Juan with the classification system of the United States Geological Service (USGS) with OLI sensor data from Landsat 8, b ) Determine which combination of B5, B4, B3 and B2 bands, it is best to classify land use and cover suelo. Para get as much image information Optimum Index Factor (OIF) was used to four combinations of bands. The classification was done with the Maximum Likelihood method using training areas with the ROI tool. The classification was validated with a confusion matrix. Subsequently classification was transformed raster to vector polygons and minor has stripped 10.1 ha.

## 1. Introducción

La clasificación supervisada y no supervisada de imágenes multiespectrales adquiridas a través de sensores remotos nos permite ordenar los diferentes elementos que componen una imagen digital de acuerdo a los valores que pueden ser de radianza, % de reflectancia y valores digitales de cada uno de los píxeles.

Utilizar un sistema de clasificación permite almacenar la información de una forma ordenada, jerárquica y determinada con lo cual se estandariza la información. La clasificación de uso del suelo y animales, aves, reptiles, anfibios, peces y plantas de humedales. El comercio de exportación que se realiza en los puertos y muelles dentro del estuario representa el 80 % de los productos importados a Puerto Rico. Este lugar recibe sobre los 1.3 millones de turistas en cruceros y 9.8 millones de viajeros en avión. En este proyecto se analizó la combinación de bandas (B2, B3, B4, B5) del sensor Operational Land Imager (OLI) de Landsat 8, utilizando el método de Índice de Factor Óptimo (OIF), para obtener la mayor cantidad de información y la menor

cobertura del suelo (Land use and land cover) es importante para diferentes investigaciones como inventario de recursos naturales, control de inundaciones, incremento del área urbana, contaminación de aguas, deforestación, que son útiles para diferentes agencias del estado para tomar decisiones (Anderson, J. et all. 1976).

La Cuenca del Estuario de San Juan es un área de importancia económica, turística y ecológica, donde encontramos una gran variedad de

cantidad de duplicados para una clasificación. Se realizó una clasificación supervisada con el método Maximum Likelihood. La clasificación obtenida por Maximum Likelihood en formato raster se exporto a un formato vector para filtrar polígonos con tamaños menores a 10.1 ha, n que es el mínimo cartografíale para la escala 1:50 000.

## 2. Objetivos

### • General

Realizar el uso del suelo y cobertura del suelo (Land use and land cover) actual de la Cuenca del Estuario de San Juan con el sistema de clasificación del United States Geological Service (USGS) con datos del sensor OLI de Landsat 8.

### • Específico

Determinar que combinación de las bandas B5, B4, B3 y B2, resulta mejor para la clasificación de uso del suelo y cobertura del suelo.

## 3. Materiales

Se utilizaron dos imágenes nivel 1, LC80040472015120LGN00 del 30 de abril de 2015 y LC80050472015127LGN00 del 7 de mayo de 2015, del sensor OLI de Landsat 8.

Mapas topográficos escala 1:20 000 de San Juna, Carolina, Bayamón, Aguas Buenas, Gurabo, Naranjito.

Sistema de Clasificación del Geological Survey Professional Paper 964.

Software ENVI 5.0

Software ArcGis 10.2

## 4. Metodología

### 4.1. Obtención de Imágenes

Las imágenes LC80040472015120LGN00 del 30 de abril de 2015 y LC80050472015127LGN00 del 7 de mayo de 2015, del sensor OLI de Landsat 8, corresponden al Path 5 y Row 47, del sistema mundial de referencia 2 (del inglés World Reference System 2 –WRS2). Las bandas de la 1 – 9,

corresponden al sensor OLI y las bandas 10 y 11, son del Termal Infrared Sensor (TIRS). Las bandas del sensor OLI poseen una resolución espacial de 30 m, excepto la banda 8 pancromática con una resolución de 15 m (Cuadro 1). Las imágenes se obtuvieron de la página de internet <http://earthexplorer.usgs.gov/>.

**Cuadro 1.** Características de las bandas espectrales y resolución espacial de los sensores OLI y TIRS.

Bands	Wavelength (micrometers)	Resolution (meters)
Band 1 - Coastal aerosol	0.43 - 0.45	30
Band 2 - Blue	0.45 - 0.51	30
Band 3 - Green	0.53 - 0.59	30
Band 4 - Red	0.64 - 0.67	30
Band 5 - Near Infrared (NIR)	0.85 - 0.88	30
Band 6 - SWIR 1	1.57 - 1.65	30
Band 7 - SWIR 2	2.11 - 2.29	30
Band 8 - Panchromatic	0.50 - 0.68	15
Band 9 - Cirrus	1.36 - 1.38	30
Band 10 - Thermal Infrared (TIRS) 1	10.60 - 11.19	100 * (30)
Band 11 - Thermal Infrared (TIRS) 2	11.50 - 12.51	100 * (30)

Fuente: [http://landsat.usgs.gov/band\\_designations\\_landsat\\_satellites.php](http://landsat.usgs.gov/band_designations_landsat_satellites.php)

### 4.2. Combinación de Bandas

Para la obtención de las diferentes combinaciones de bandas se utilizó un arreglo de combinaciones. En este arreglo no se considera el orden y no puede existir repetición de r elementos formado de un conjunto de n elementos.

$$nCr = \frac{n!}{(n-r)!r!} \quad (1)$$

Donde

n = número de elementos (bandas)

r = número de arreglos (combinaciones)

### 4.3. Unión de Bandas

Para la unión de las cinco bandas B1, B2, B3, B4, B5 y B8, se utilizó la herramienta Layer Staking, para cada imagen.

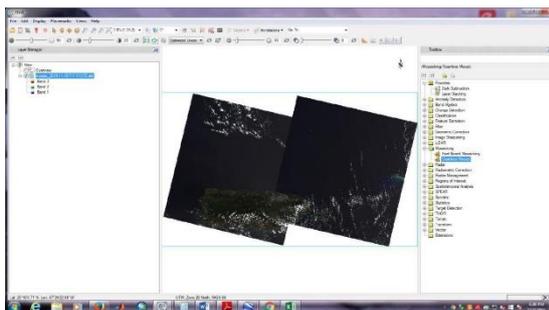
### 4.4. Cambio de resolución espacial (Sharpening)

Para el cambio de la resolución espacial de 30 m a 15 m con el uso de la banda 8 pancromática se utilizó la herramienta

NNDiffuse Pan Sharpening de ENVI. Para el uso de esta herramienta los archivos raster de las diferentes bandas deben ser múltiplo del tamaño del pixel de alta resolución y estar en la misma proyección (Exelis, 2015). La herramienta está ubicada en Toolbox | Image Sharpening | NNDiffuse Pan Sharpening.

### 4.5. Mosaico

La unión de las imágenes se realizó con la herramienta Seamless Mosaic de ENVI. Ubicado en Toolbox | Mosaicking | Seamless Mosaic.



**Imagen 1.** Proceso de unión de bandas con la herramienta Seamless Mosaic.

### 4.6. Índice de Factor Óptimo (OIF)

El Índice de Factor Óptimo, se obtiene de la sumatoria de las desviaciones estándar de cada una de las bandas que conforman la combinación, dividido para los valores absolutos de sus correlaciones (Guifang Zhang. et al. 2011; Mijanur Rahman. et al. 2013).

$$OIF = \sum_{i=1}^n \left( \frac{\sigma_i}{\sum_{j=1}^n |r_{ij}|} \right) \quad (2)$$

Reemplazando los valores de la ecuación 2.

$$OIF = \frac{Std1 + Std2 + Std3}{|Corr1,2| + |Corr1,3| + |Corr2,3|} \quad (3)$$

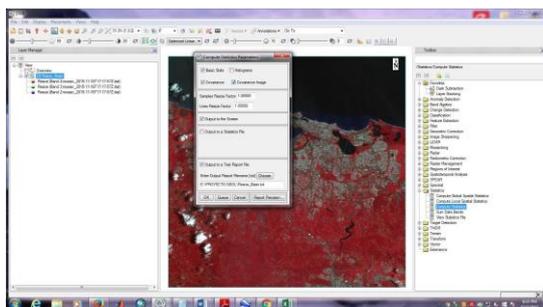
Donde

Std = desviación estándar

Corr = correlación

El Índice de Factor Óptimo, permite obtener la mayor cantidad de información y la menor cantidad de duplicados de una imagen para una clasificación. La combinación de bandas que se debe utilizar es la aquella presenta el mayor Índice de Factor Óptimo.

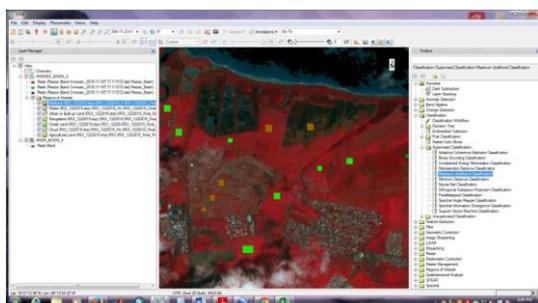
Los valores estadísticos como la desviación estándar, correlación máximo, mínimo y otros de para cada una de las bandas se obtiene con la herramienta Compute Statistics de ENVI. La herramienta está ubicada en Toolbox | Statistics | Compute Statistics



**Imagen 2.** Valores estadísticos utilizando la herramienta Compute Statistics.

#### 4.7. Mascara y clasificación

Para la clasificación se aplicó una máscara a los cuerpos de agua con la banda 5. Los valores que se utilizaron fueron de 10753 a 58928. Posteriormente se utilizó los ROIs para las áreas de entranamiento de las diferentes clases o categorías identificadas en la imagen mediante observación. Una vez digitalizado las diferentes áreas de entrenamiento se procedió a realizar la clasificación supervisada con la herramienta MaximumLikelihood.



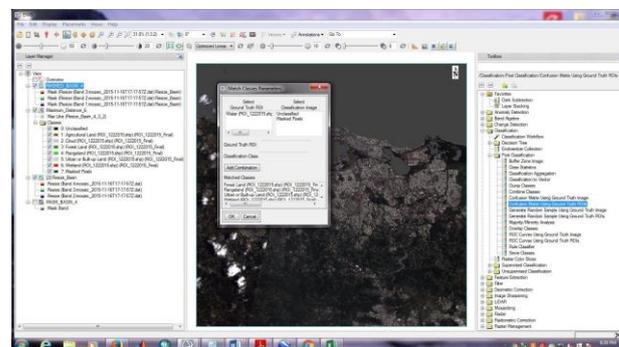
**Imagen 3.** ROIs de las áreas de entrenamiento para la clasificación supervisada con el método Maximum Likelihood.

#### 4.8. Matriz de confusión o matriz de error

La matriz de confusión de para una clasificación se obtiene con la herramienta Confusion Matrix Using Ground Truth ROIs. La herramienta se encuentra ubicada en Toolbox | Classification | Post Classification | Confusion Matrix Using Ground Truth ROIs. La matriz de confusión nos permite

identificar la cantidad de píxeles que se clasificaron correctamente y la cantidad de píxeles que se clasificaron incorrectamente dentro de otra categoría. En las etiquetas de las categorías al lado izquierdo de la clasificación de la imagen de referencia mientras que en la parte horizontal superior se encuentran las etiquetas de las categorías a ser evaluadas. En la última fila se muestra la sumatoria de píxeles asignados a cada clase o categoría.

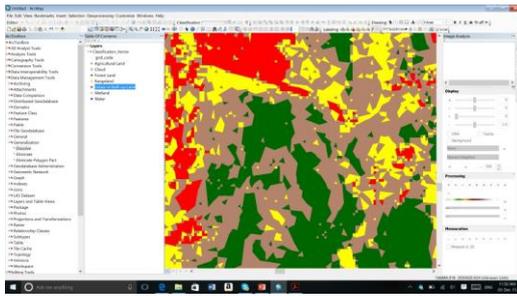
Para que una clasificación se considere como satisfactoria, debe tener un 85 % de precisión (Anderson et al. 1976). En otros estudios realizados a diferentes escalas se reporta que la precisión debe ser de 85 % (1: 24000), 77 % (1: 100000), y 73 % (1: 25000) (Fitzpatrick-Lins. 1978, citado por Cambell).



**Imagen 4.** Uso de la herramienta Confusion Matrix Using Ground Truth ROIs, para la clasificación de Maximum Likelihood.

#### 4.9. Vectorización

Una vez validada la información se procedió a la vectorización a formato shapefile, de la clasificación obtenida con Maximum Likelihood. Posteriormente se realizó una depuración de los polígonos menores a 10.1 ha que no cumplen con el mínimo cartografiable para la escala 1:50000, con la herramienta Eliminate de ArcGis.



**Imagen 5.** Utilización de la herramienta Eliminate para la eliminación de los polígonos menores a 10.1 ha.

### 5. Resultados

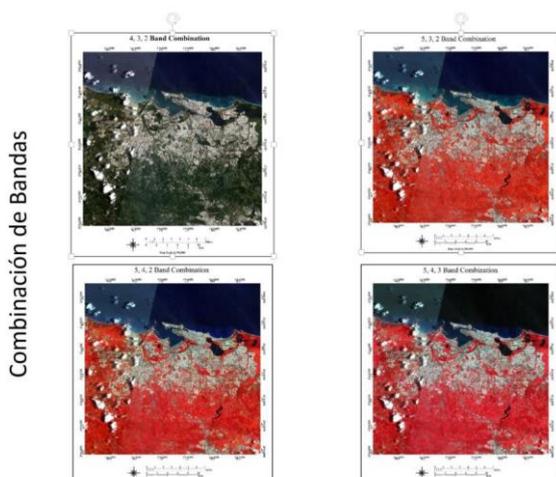
Utilizando la ecuación 1, para 3 arreglos de 4 elementos (bandas B2, B3, B4 y B5) el resultado es el siguiente.

$$4C3 = \frac{4!}{(4 - 3)! 3!}$$

En el Cuadro 2, se observa las 4 combinaciones de bandas que se utilizaron para el Índice de Factor Optimo.

**Cuadro 2.** Combinaciones para las bandas B2, B3, B4 y B5 del sensor OLI, de Landsat 8.

Combinaciones	Bandas
1	4 - 3 - 2
2	5 - 3 - 2
3	5 - 4 - 2
4	5 - 3 - 4



**Imagen 5.** Visualización de las combinaciones de banda 1, 2, 3 y 4.

En el Cuadro 3, se observa los valores de mínimo, máximo y desviación estándar para las bandas 2, 3, 4, y 5 obtenidas con la herramienta Compute Statistic.

**Cuadro 3.** Estadísticas descriptivas para las cuatro bandas del sensor OLI, Landsat 8.

Ban	M	M	Mea	Stde
Band 0	0	5003	11645.24	2173.121
Band 0	0	6537	10853.43	2453.425
Band 0	0	5535	10174.50	2852.019
Band 0	0	5912	16604.00	6020.943

**Cuadro 4.** Correlación entre las cuatro bandas del sensor OLI, de Landsat 8.

Correlation	Band 2	Band 3	Band 4	Band 5
Band 2	1	0.936728	0.937398	0.243273
Band 3	0.936728	1	0.977306	0.468239
Band 4	0.937398	0.977306	1	0.453899
Band 5	0.243273	0.468239	0.453899	1

Reemplazando los valores de los Cuadros 3 y 4 en la ecuación 3, para las combinaciones 1, 2, 3 y 4, se obtuvo los siguientes Índices de Factor Optimo.

La combinación de bandas que presento mejor Índice de Factor Optimo (OIF), fue la combinación de bandas 5, 4, 2 del sensor OLI con un valor de 6757.79 (Cuadro 5).

**Cuadro 5.** Índice de factor óptimo para las cuatro combinaciones de bandas del sensor OLI, Landsat 8.

Bands combination	OIF
4-3-2	2622.740515
5-3-2	6459.914704
5-4-2	6757.792157
5-4-3	5963.001599

La clasificación supervisada con el método Maximum Likelihood y con el uso de áreas de entrenamiento se obtuvo seis clases del Nivel 1: agricultural, forest land, rangeland, urban or build-up, wetland y water (corresponde a los valores de la mascara). La precisión general fue de 93.25 %, que es

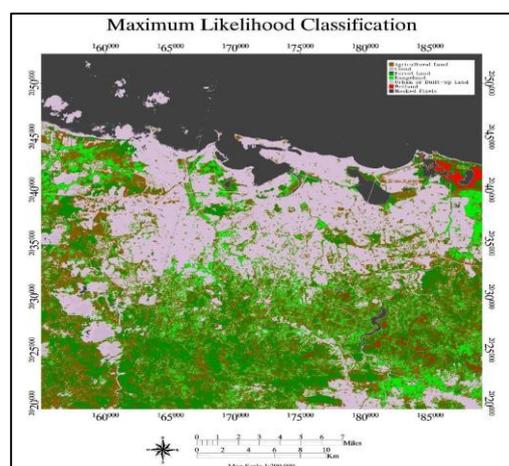
satisfactoria para la clasificación de uso y cobertura de la tierra.

De la matriz de confusión o matriz de error, se observa que la clase agricultura obtuvo errores de clasificación por omisión con bosques (Forest Land) y humedales (wetland). La clase urbana o acumulación (urban or build-up) presenta errores de clasificación con nubes y agricultura. La clase de humedales presentó errores de clasificación con bosque. La razón de estos errores es principalmente a que existe una reflexión espectral similar (Cuadro 7).

**Cuadro 6.** Matriz de confusión para seis clases, de la clasificación Maximum Likelihood.

Classifications	Agricultural	Cloud	Forest Land	Rangeland	Urban or Build-up Land	Wetland	Total
Agricultural	199	0	6	69	0	0	274
Cloud	0	738	0	0	27	0	765
Forest Land	0	0	1786	0	0	14	1800
Rangeland	87	0	0	1010	0	0	1097
Urban or Build-up Land	4	21	0	0	2228	0	2253
Wetland	0	0	214	0	0	149	363
<b>Total</b>	<b>290</b>	<b>759</b>	<b>2006</b>	<b>1079</b>	<b>2255</b>	<b>163</b>	<b>6110</b>

**Cuadro 7.** Precisión de la clasificación Maximum Likelihood, para las seis clases.



**Imagen 6.** Clasificación supervisada realizada con el método Maximum Likelihood.

En la imagen 7, se observa el shapefile resultado de la vectorización de la clasificación realizada por Maximum likelihood.

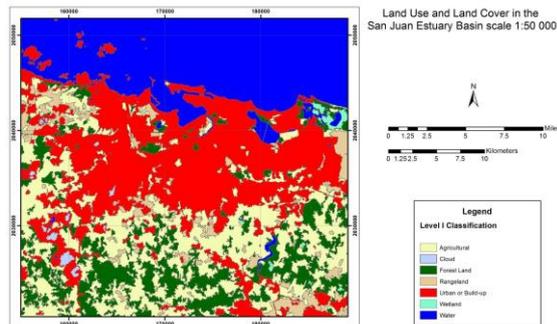


**Imagen 7.** Vectorización de la clasificación de Máximo Likelihood.

En la Imagen 8 se observa el proceso de depuración de los polígonos menores a 10.1 ha, para la escala 1:50000.



**Imagen 8.** Clasificación depurada.



**Imagen 9.** Resultado final de la clasificación con Maximum Likelihood, para la Cuenca del Estuario de San Juan. Conclusiones

El Índice de Factor Optimo, permitió la mejor combinación de bandas para la clasificación supervisada mediante la técnica de Maximum Likelihood.

La clasificación supervisada con el método de Maximum Likelihood y el uso de áreas de entrenamiento de las imágenes LC80040472015120LGN00 y LC80050472015127LGN00 del sensor OLI de Landsat 8, con un tamaño de pixel de 15 m, obtenidas mediante la técnica de NNDiffuse Pan Sharpening permiten únicamente la clasificación del Nivel de Clasificación I.

La clasificación de Nivel II, no se puede realizar mediante interpretación visual, principalmente en zonas antropomórficas

donde es necesario la recolección de información.

## 7. Referencias

Boul, S.W., R.J. Southard, R.C. Graham and P.A. McDaniel. 2011. Soil genesis and classification. 6<sup>th</sup> ed. Wiley & Sons, Inc. Iowa State Univ, Ames. 397 – 423 p.

Campbell, J.B. 2007. Introduction to remote sensing. 4th ed. Guilford Publications. NY. US. 392 – 409 p.

Exelis. 2015. NN NNDiffuse Pan Sharpening. Consultado el 15 de diciembre de 2015. Disponible:<http://www.exelisvis.com/docs/NNDiffusePanSharpening.html>.

GUIFANG ZHANG, ZHUO ZHENG, XIAOHUO SHEN\$, LEJUN ZOU\$and KANGYOU

HUANG. 2011. Remote sensing interpretation of areas with hydrocarbon microseepage in northeast China using Landsat-7/ETM+ data processing techniques. Vol. 32, No. 21. doi:10.1080/01431161.2010.512940.

Md. Mijanur Rahmana, Md. Rahmat Ullahb, MiLanc, J.T. Sri Sumantod, H. Kuzed, and R. Tateishic. 2013. Comparison of Landsat image classification methods for detecting mangrove forests in Sundarbans. International Journal of Remote Sensing. Vol. 34, No. 4. doi: 10.1080/01431161.2012.717181.