



PERÚ

Ministerio  
de Agricultura y Riego



# Manual Técnico

METODOLOGÍA PARA CLASIFICACIÓN DE COBERTURAS  
A PARTIR DEL PROCESAMIENTO DE IMÁGENES  
SATELITALES



MEJORAMIENTO DEL SISTEMA DE INFORMACIÓN  
ESTADÍSTICA AGRARIA Y DEL SERVICIO DE INFORMACIÓN  
AGRARIA PARA EL DESARROLLO RURAL DEL PERÚ





PERÚ

Ministerio  
de Agricultura y Riego



# Manual Técnico

METODOLOGÍA PARA CLASIFICACIÓN DE COBERTURAS  
A PARTIR DEL PROCESAMIENTO DE IMÁGENES  
SATELITALES



MEJORAMIENTO DEL SISTEMA DE INFORMACIÓN  
ESTADÍSTICA AGRARIA Y DEL SERVICIO DE INFORMACIÓN  
AGRARIA PARA EL DESARROLLO RURAL DEL PERÚ

Este Manual se ejecutó en el Marco del Convenio de Contrato 002-2017-MINAGRI-DVDIAR-UEGPS/DE-PIADER y el Consorcio AIDER y SOUTH POLE CARBON ASSET MANAGEMENT.



REPÚBLICA DEL PERÚ

Pedro Pablo Kuczynski  
Presidente Constitucional del Perú

MINISTERIO DE AGRICULTURA Y RIEGO

José Berley Arista Arbildo  
**Ministro de Agricultura y Riego**

Jorge Luis Maicelo Quintana  
**Viceministro de Desarrollo e Infraestructura Agraria y Riego**

Juan José Marcelo Risi Carbone  
**Viceministro de Políticas Agrarias**

José Revilla Vuelot  
Director Ejecutivo  
**Unidad Ejecutora Gestión de Proyectos Sectoriales - UEGPS**

Christian Alejandro Garay Torres  
Director General  
**Dirección General de Seguimiento y Evaluación de Políticas**

Manuel Eduardo Castro Larrea  
Director  
**Dirección de Estadística Agraria – DGESEP**

Máximo Alexander Juárez Amaya  
Coordinador General  
**Proyecto PIADER - UEGPS**

Proyecto “**Mejoramiento del sistema de información estadística agraria y del servicio de información agraria para el desarrollo rural del Perú**” – PIADER  
Contrato de Préstamo N° 3272/OC-PE

Manual técnico “**Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales**”

Autor:

Unidad Ejecutora 001631: Gestión de Proyectos Sectoriales - UEGPS  
Ministerio de Agricultura y Riego

Editado por:

Unidad Ejecutora 001631: Gestión de Proyectos Sectoriales - UEGPS  
Av. General Trinidad Morán N° 955 Urb. Risso - Lince.  
Lima -fPerú

Website: <https://uegps.gob.pe>

1a. edición - Febrero 2018

HECHO EL DEPÓSITO LEGAL EN LA BIBLIOTECA NACIONAL DEL PERÚ N° 2018-02480

Se terminó de imprimir en febrero del 2018 en:

ESERGRAF

Ediciones y Servicios Gráficos

Jr. Los Halcones 293 - 3er piso

Bellavista - Callao

# INTRODUCCIÓN

---

El presente manual técnico **“Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales”**, ha sido elaborado en el marco de la ejecución del Proyecto Mejoramiento del Sistema de Información Estadística Agraria y del Servicio de Información Agraria para el Desarrollo Rural en el Perú – PIADER de la Unidad Ejecutora de Gestión de Proyectos Sectoriales – UEGPS, y en coordinación con la Dirección de Estadística Agraria – DEA de la Dirección General de Seguimiento y Evaluación de Políticas – DGESEP, pertenecientes al Ministerio de Agricultura y Riego – MINAGRI, integrantes del Sistema Integrado de Estadísticas Agrarias – SIEA.

Esta iniciativa, desarrollada en el marco del PIADER, financiada parcialmente por el Banco Interamericano de Desarrollo, corresponde a una de las acciones programadas en el proyecto, con miras a la modernización del Sistema Estadístico Agrario del país; a través de la incorporación de modernas técnicas, metodologías y tecnologías, para la generación de información agraria de calidad, oportuna y confiable, que conlleva a una mejor toma de decisiones por parte de los agentes agrarios del país, y en particular de los productores agrarios a nivel nacional.

El manual técnico **“Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales”**, se ha formulado con la finalidad de facilitar una herramienta moderna a los especialistas dedicados al procesamiento de imágenes satelitales de alta resolución, y en este caso a los especialistas de la DEA - DGESEP, Direcciones de Información Agraria o Estadística Agraria de las Direcciones Regionales Agrarias del país, y actores agrarios que deseen contribuir con el país, a través de la incorporación de este valioso activo de “imágenes satelitales”, como una nueva forma de generar información agraria, y que se constituya como activo e información esencial para el monitoreo de la dinámica agraria del país.

Agradecemos a los directivos, coordinadores y especialistas técnicos de la UEGPS – PIADER, DEA – DGESEP, BID, así como también al Consorcio AIDER - South Pole, que contribuyeron en la elaboración del presente manual.

**Proyecto PIADER - UEGPS**





# GENERALIDADES

---

ENVI es un programa construido sobre el lenguaje (IDL), especializado en el manejo de datos multidimensionales y su visualización. Se diferencia de otros programas similares (MATLAB, por ejemplo) en que contiene funciones especialmente adaptadas al trabajo con información territorial o geográfica. ENVI se caracteriza por ser multiplataforma, existiendo versiones que corren en WINDOWS, LINUX y varias versiones de UNIX, lo que lo hace muy versátil y adaptable. Este mismo hecho ha hecho que exista una importante cantidad de programas y utilidades desarrolladas en todo el mundo que se pueden obtener gratuitamente en la WEB y que permiten incrementar las capacidades del software.

IDL (Interactive Data Language) es el lenguaje de programación científico, utilizado en todas las disciplinas para crear visualizaciones significativas de datos numéricos complejos. Desde pequeños programas de análisis hasta el desarrollo de una gran variedad de aplicaciones, IDL proporciona el entorno informático integral que necesita para obtener eficazmente información a partir de sus datos. IDL es, pues, una herramienta para que científicos, investigadores, ingenieros y demás interesados puedan procesar, analizar, tratar datos y crear aplicaciones de forma rápida y eficaz. Se trata de un lenguaje de programación aplicado al procesamiento y análisis de matrices con independencia de sus dimensiones. Esta característica hace de IDL un lenguaje de programación ideal para el tratamiento de imágenes RapidEye.



## ÍNDICE

Introducción	5
Generalidades	6
I. ¿Qué es Envi?	15
II. Envi + idl, Envi, e idl	15
III. Acerca de esta unidad	15
IV. Objetivos de aprendizaje	15
V. Conocimientos previos	16
VI. Herramientas requeridas para completar esta unidad	16
VII. Archivos utilizados en esta unidad	16
VIII. Procesamiento de imágenes	
1. Transformación de los ND a valores de radiancia espectral	19
2. Transformación de la radiancia a valores de reflectancia	27
3. Unión de bandas espectrales y cálculo del NDVI	30
4. Análisis espectral de las imágenes RapidEye	33
5. Mosaico de imágenes	36
6. Normalización de imágenes	40
IX. clasificación de coberturas	56
1. Preparación datos de entrada (Workflow)	57
2. Segmentación de la imagen	59
2.1. Configuración de la segmentación (Segmentation settings)	59
2.2. Configuración de la integración de segmentos (Merge settings)	60
2.3. Configuración de clasificados por textura (Texture kernel size)	60
3. Clasificación de la imagen segmentada	61
3.1. Selección de las semillas o áreas de entrenamiento	61
3.2. Análisis de separabilidad de las áreas de entrenamiento	64
3.3. Selección de los parámetros de clasificación	66
3.4. Exportar los archivos de clasificación	67
4. Procesamiento post clasificación	68
5. Cálculo del error de clasificación	68
5.1. Cálculo del tamaño de la muestra de segmentos de control	69
5.2. Obtención de la muestra de segmentos de control	69
5.3. Cálculo del error	75
Referencias	80
X. Complemento metodológico de clasificación de cobertura	81
1. Antecedentes del eCognition	82
2. Características espectrales de la imagen RapidEye	83
3. Abrir el software eCognition.	85
4. Visualizar objetos de una imagen.	87
5. Visualizar los resultados de una clasificación.	88
6. Otras funciones.	88
7. Ventanas esenciales para el desarrollo de conjunto de reglas	89
7.1. Image Object Information, Feature View	89
7.2. Class Hierarchy (Jerarquía de clases)	91

7.3	Process Tree (Árbol de procesos)	91
8	Estudio de caso - Segmentación y Clasificación.	92
8.1	Proceso de segmentación	98
8.1.1	Segmentación	98
8.1.2	Segunda segmentación	99
8.2	Proceso de clasificación	100
8.2.1	Inclusión de clases	100
8.2.2	Toma de muestras	101
8.2.3	Proceso de clasificación.	103
8.2.4	Exportación de resultados	106

## LISTA DE TABLAS

Tabla 1. Archivos de imágenes RapidEye	16
Tabla 2. Ruta de trabajo	21
Tabla 3. Características de la condición atmosférica	26
Tabla 4. Características de la condición atmosférica	28
Tabla 5. Ruta de trabajo para el proceso de apilamiento	30
Tabla 6. Imágenes RapidEye en reflectancia apiladas	31
Tabla 7. Ubicación del pixel	35
Tabla 8. Coberturas a clasificar	63
Tabla 9. Características de las imágenes RapidEye	83
Tabla 10. Productos de las imágenes RapidEye	84
Tabla 11. Visualización de objetos	88
Tabla 12. Visualización de la clasificación	88
Tabla 13. Otras funciones	89
Tabla 14. Parámetros y formatos para exportar los resultados	106

## LISTA DE FIGURAS

Figura 1. Ejemplo de la carpeta de trabajo	16
Figura 2. Carpeta “CÓDIGOS DE CALIBRACIÓN”	17
Figura 3. Carpeta “CÓDIGOS DE NORMALIZACIÓN”	17
Figura 4. Carpeta “DATA RAPIDEYE”	18
Figura 5. Carpeta “EJECUTABLE 6S”	18
Figura 6. Carpeta “RESULTADOS”	19
Figura 7. Apertura de ENVI 5.3 + IDL 8.5	20
Figura 8. Apertura del código RADIANCIA_RAPIDEYE.pro	21
Figura 9a. Información de la fecha de adquisición de la imagen	22
Figura 9b. Información de los ángulos	22
Figura 9c. Información de la dimensión de la imagen, Datum y proyección	23
Figura 9d. Coeficiente de calibración de la banda 1 de RapidEye	23
Figura 10. Fin del procesamiento de la radiancia	24
Figura 11. Imágenes RapidEye calibradas a valores de radiancia	25
Figura 12. Archivos del proceso de la radiancia	25
Figura 13. Condición atmosférica	26
Figura 14. Modo batch	27
Figura 15. Procesamiento por lotes	27
Figura 16. Corrección atmosférica	28
Figura 17. Archivos del procesamiento de imágenes	29
Figura 18. Código de “UNION_DE_BANDAS.pro”	30
Figura 19. Procesamiento del NDVI y de la unión de bandas	31
Figura 20. Imágenes RapidEye apiladas	32
Figura 21. Imágenes NDVI derivado de la reflectancia	32
Figura 22. Apertura de las imágenes de reflectancia usando ENVI clásico	33

Figura 23. Apertura de las imágenes de reflectancia usando ENVI	34
Figura 24. Apertura de la herramienta “Spectral”	35
Figura 25. Análisis espectral del agua, vegetación y del suelo	36
Figura 26. Apertura del módulo de mosaico	37
Figura 27. Selección de las imágenes para realizar el mosaico	37
Figura 28. Selección de las imágenes para realizar el mosaico	38
Figura 29. Selección de las imágenes para realizar el mosaico	38
Figura 30. Visualización del mosaico 2011-06-28	39
Figura 31. Visualización del mosaico 2011-08-14	39
Figura 32. Visualización del mosaico en combinación de bandas 532	40
Figura 33. Visualización del mosaico en combinación de bandas 532	41
Figura 34. Apertura de las Imágenes	42
Figura 35. Función de recorte de imagen	42
Figura 36. Selección de la imagen a ser cortada	43
Figura 37. Selección de la imagen que será cortada	43
Figura 38. Selección de la imagen base	44
Figura 39. Salida de la imagen 2011-08-14-CUT	44
Figura 40. Salida de la imagen 2011-08-14-CUT y 2011-06-28-CUT	45
Figura 41. Cálculo de la estadística de imagen	45
Figura 42. Histograma de imágenes	46
Figura 43. Selección de la herramienta mad-run	46
Figura 44. Transformación de BSQ a BIP	47
Figura 45. Selección de puntos para la iteración y la penalización	47
Figura 46. Salida de los archivos MAD, CV y MAD Stats	48
Figura 47. Correlación de las imágenes 2011-08-14-CUT y 2011-06-28-CUT	49
Figura 48. Salida de los archivos MAD y CV	49
Figura 49. Activación del módulo Radiometric Normalization	50
Figura 50. Selección de la imagen base 2011-08-14-cut	51
Figura 51. Selección de la imagen base 2011-06-28-cut	51
Figura 52. Selección de la imagen chi cuadrado	52
Figura 53. Selección mínima de probabilidad de no cambio	52
Figura 54. Salida de la imagen normalizada 2011-06-28-cut-N	53
Figura 55. Salida de la imagen normalizada 2011-06-28-N	53
Figura 56. Estadística de la normalización de la imagen 2011-06-28-N	54
Figura 57. Correlaciones de los 5928 puntos de la imagen 2011-06-28-N	54
Figura 58. Visualización del MOSAICO-N en combinación de bandas 532	55
Figura 59. Proceso metodológico para la clasificación de coberturas	56
Figura 60. Example Based Feature Extraction Workflow	57
Figura 61. Data Selection – Select Input Files – Input Raster	57
Figura 62. Data Selection – Select Input Files – Input Mask (Ancillary Data)	58
Figura 63. Data Selection – Select Input Files – Custom Bands	58
Figura 64. Parámetros de segmentación	59
Figura 65. Ajustes de segmentación	60
Figura 66. Ajustes de Merge	60
Figura 67. Ventana de clasificación o de elección de semillas	61

Figura 68. Imagen segmentada	62
Figura 69. Imagen segmentada	62
Figura 70. Ventana para cargar las áreas de entrenamiento	64
Figura 71. Forma de cargar las semillas en la herramienta ROI en ENVI	65
Figura 72. Ruta para acceder a la herramienta de cómputo de separabilidad de áreas de entrenamiento	65
Figura 73. Ejemplo de reporte de análisis de separabilidad de áreas de entrenamiento	66
Figura 74. Selección de atributos	66
Figura 75. Selección de algoritmos	67
Figura 76. Guardado de clasificación en formato shape o GDB	68
Figura 77. Opciones de la herramienta Feature to Raster del ArcMap	70
Figura 78. Raster de la clasificación final	70
Figura 79. Herramienta “Create Accuracy Assessment Points”	71
Figura 80. Resultado de la creación de puntos de control	71
Figura 81. Herramienta para la selección de polígonos que coinciden con los puntos de control	72
Figura 82. Polígonos coincidentes con los puntos de control	72
Figura 83. Herramienta para exportar los polígonos coincidentes con los puntos de control	73
Figura 84. Set de polígonos de control	73
Figura 85. Herramienta para crear columnas en la tabla de atributos	74
Figura 86. Tabla de atributos de la muestra de segmentos de control con la columna Predict diligenciada	74
Figura 87. Conversión de polígonos a puntos de los segmentos de control	75
Figura 88. Resultado de la conversión de polígonos a puntos de los segmentos de control	76
Figura 89. Creación de nuevas columnas al vector con puntos de control	76
Figura 90. Tabla de atributos de la clasificación (segmentación) para el cálculo del error	77
Figura 91. Tabla de atributos de la muestra (valor estimado)	77
Figura 92. Borrado de campos del resultado del cálculo del error	78
Figura 93. Resultado final del borrado de campos del cálculo del error	78
Figura 94. Ventana del Compute Confusion Matrix	79
Figura 95. Matriz de confusión	79
Figura 96. Tecnología de red cognitiva.	82
Figura 97. Características espectrales para las coberturas	84
Figura 98. Apertura del software eCognition	85
Figura 99. Selección del modo de trabajo	85
Figura 100. Visualización general del software	86
Figura 101. Módulos de trabajo	86
Figura 102. Interface de trabajo	87
Figura 103. Interface de trabajo	89
Figura 104. Índices y bandas de las imágenes	90
Figura 105. Datos estadísticos de los segmentos	90

Figura 106. Árbol jerárquico de clases	91
Figura 107. Árbol de procesos de algoritmos	91
Figura 108. Árbol jerárquico de clases	92
Figura 109. Nuevo proyecto	93
Figura 110. Carpeta de la imagen	93
Figura 111. Características de la imagen a trabajar	94
Figura 112. Edición de nombres de las bandas	94
Figura 113. Edición de nombres de las bandas	95
Figura 114. Creación de proyectos	95
Figura 115. Visualización por defecto de la imagen	96
Figura 116. Cambio de la combinación de bandas para la visualización	96
Figura 117. Combinación de bandas RGB 543	97
Figura 118. Generación del Árbol de procesos	97
Figura 119. Algoritmo de segmentación	98
Figura 120. Parámetros de la segmentación	99
Figura 121. Segunda segmentación	99
Figura 122. Clases a clasificar	101
Figura 123. Muestreo de semillas	102
Figura 124. Variables a considerar para la toma de muestras	103
Figura 125. Ingreso de algoritmos para la segmentación	104
Figura 126. Parámetros para la clasificación	104
Figura 127. Parámetros de la aplicación de la segmentación	105
Figura 128. Resultados de la clasificación	105
Figura 129. Exportar resultados	106



## I. ¿QUÉ ES ENVI?

ENVI es el software para la visualización, análisis, y presentación de todo tipo de imágenes digitales. El software de procesamiento de imágenes de ENVI incluye herramientas avanzadas, pero fáciles de usar, para realizar análisis espectral, corrección geométrica, análisis del terreno, análisis de datos radar, capacidad GIS para raster y vector, amplio soporte de una gran variedad de fuentes de imágenes entre otros. ENVI puede usarse para llevar a cabo numerosas técnicas de análisis de imágenes, como clasificación multispectral, para aplicar diversos tipos de filtros, georreferenciación de imágenes, transformación a componentes principales, cocientes de bandas y estadísticas de imagen. ENVI también cuenta con un conjunto de herramientas avanzadas para el análisis espectral, diseñadas específicamente para trabajar con datos hiperespectrales y un conjunto completo de herramientas para trabajar con datos de RADAR. Además, ENVI proporciona acceso completo al lenguaje de programación IDL (Interactive Data Language) un potente y fácil de usar, lenguaje de programación cuyos programas pueden ser incorporados fácilmente a ENVI.

## II. ENVI + IDL, ENVI, e IDL

ENVI se mejora complementándolo con IDL (Interactive Data Language). IDL es un lenguaje de programación estructurado de gran alcance que ofrece un procesamiento de imágenes integrado. La flexibilidad de ENVI se debe, en gran parte, a las capacidades que le brinda IDL.

## III. ACERCA DE ESTA UNIDAD

Este manual está diseñado para que sirva de ayuda en el proceso de aprendizaje en el procesamiento digital de imágenes y sigue un proceso metodológico ordenado. Sin embargo, la mayoría de los ejercicios en este manual son dependientes entre sí. En la mayoría de los casos se tiene que respetar el orden de los procesos para trabajar el ejercicio.

## IV. OBJETIVOS DE APRENDIZAJE

En esta unidad usted aprenderá como:

- Transformar los ND a valores de radiancia espectral
- Transformar la radiancia espectral a reflectancia de superficie
- Generar el NDVI
- Generar mosaico espectral
- Normalizar imágenes
- Clasificar digitalmente imágenes orientadas a objetos

## V. CONOCIMIENTOS PREVIOS

Para esta unidad es necesario contar con un conocimiento básico de teledetección.

## VI. HERRAMIENTAS REQUERIDAS PARA COMPLETAR ESTA UNIDAD

- ENVI 5.1
- IDL 8.3

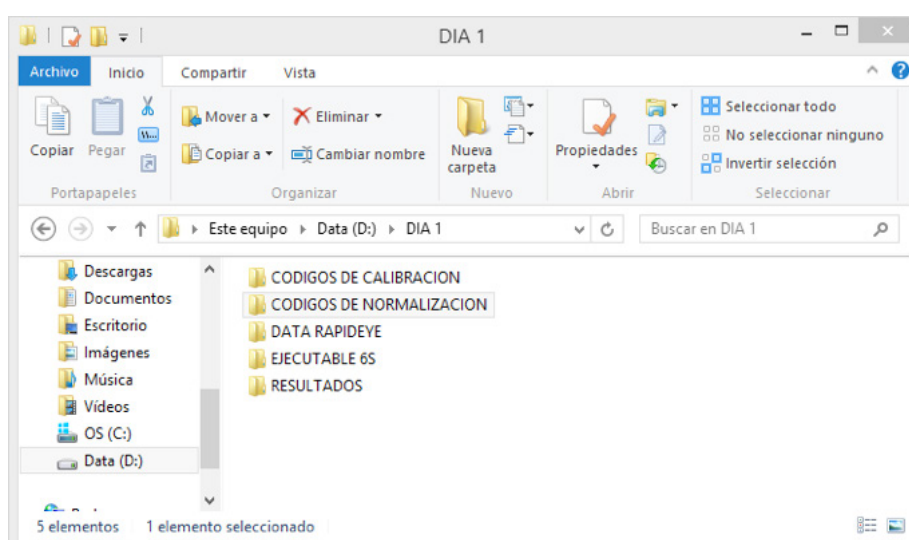
## VII. ARCHIVOS UTILIZADOS EN ESTA UNIDAD

Para el desarrollo de esta unidad se usará cuatro imágenes RapidEye que corresponden al departamento de Tumbes (Tabla 1), programas hechos en IDL y algunos ejecutables de modo Batch. Estos datos se encuentran dentro del archivo “DÍA 1” el cual se entregará a los asistentes del taller mediante un CD/DVD/USB.

**Tabla 1.** Archivos de imágenes RapidEye

ID	ARCHIVOS RAPIDEYE
1	1737217_2011-08-14_RE4_3A_160937
2	1737218_2011-08-14_RE4_3A_160937
3	1737317_2011-06-28_RE4_3A_160935
4	1737318_2011-06-28_RE4_3A_160935

Se recomienda guardar el archivo “DÍA 1” en una unidad del disco de la PC (Figura 1).



**Figura 1.** Ejemplo de la carpeta de trabajo

Dentro de la carpeta “DÍA 1” se encontrará varias carpetas, como se muestra en la figura 1. Dentro de la carpeta “CÓDIGOS DE CALIBRACIÓN” se encuentran tres programas en IDL para el pre procesamiento de las imágenes RapidEye (Figura 2).

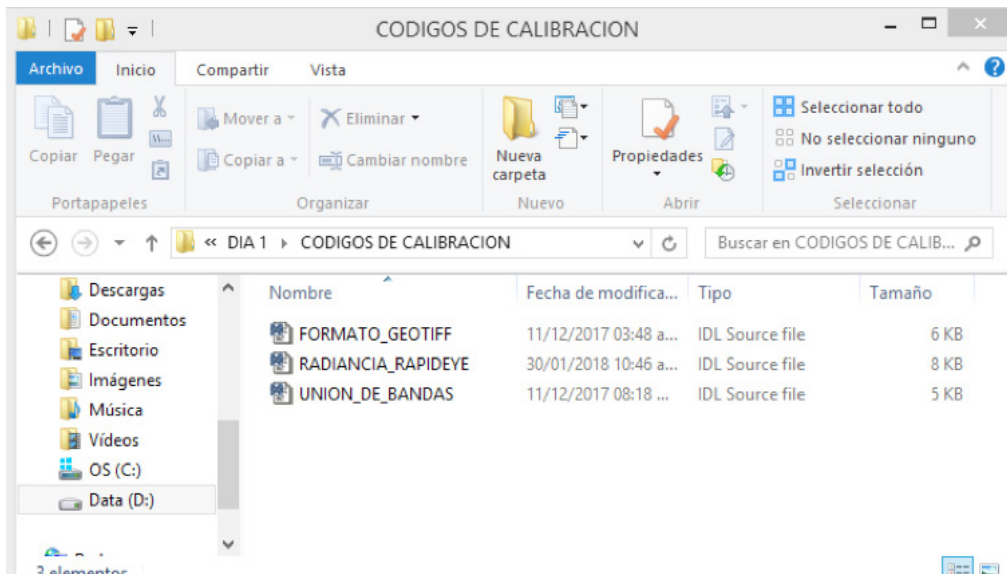


Figura 2. Carpeta “CÓDIGOS DE CALIBRACIÓN”

En la carpeta “CÓDIGOS DE NORMALIZACIÓN” se encuentran dos carpetas de nombre “CANTY” y “COYOTE” (Figura 3), estas carpetas contienen las librerías en IDL para la normalización de imágenes.

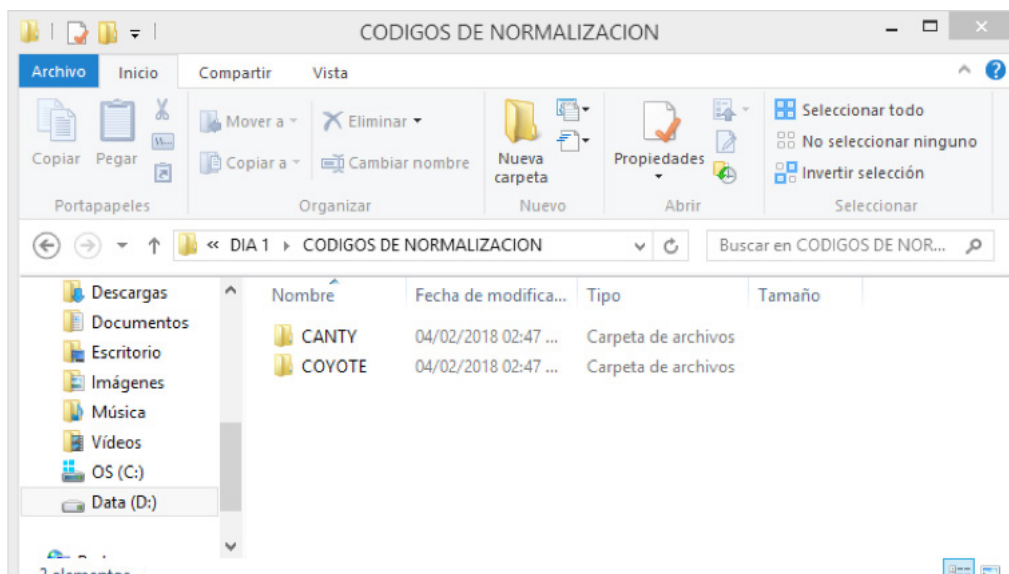


Figura 3. Carpeta “CÓDIGOS DE NORMALIZACIÓN”

En la carpeta “DATA RAPIDEYE” se encuentran cuatro imágenes RapidEye (Figura 4), estas imágenes son de nivel 3A.

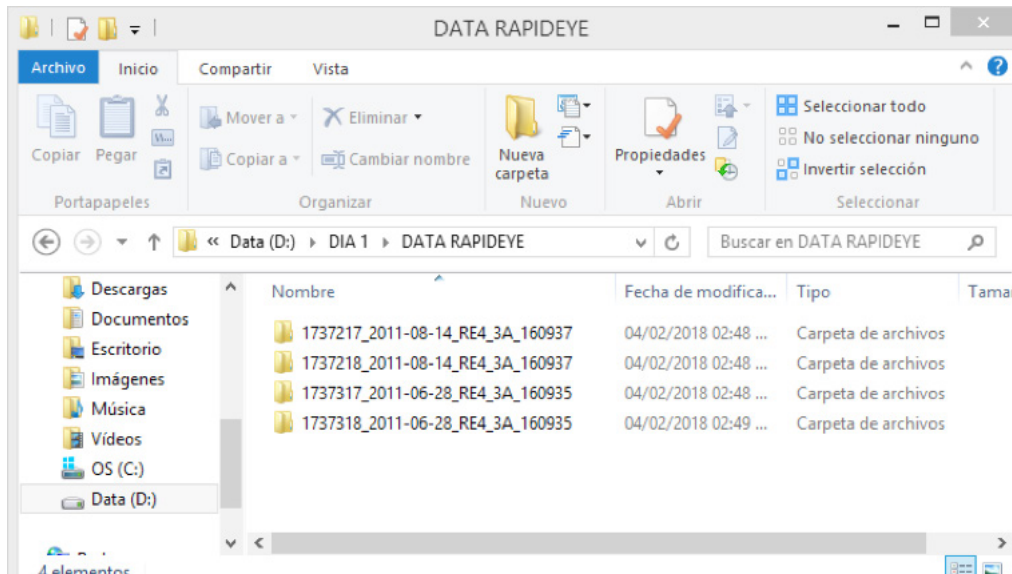


Figura 4. Carpeta “DATA RAPIDEYE”

En la carpeta “EJECUTABLE 6S” se encuentra un archivo Atmcor4RapidEye.exe y “Batch\_AtmsCor4RapidEye\_Uint16Bits.bat” (Figura 5)

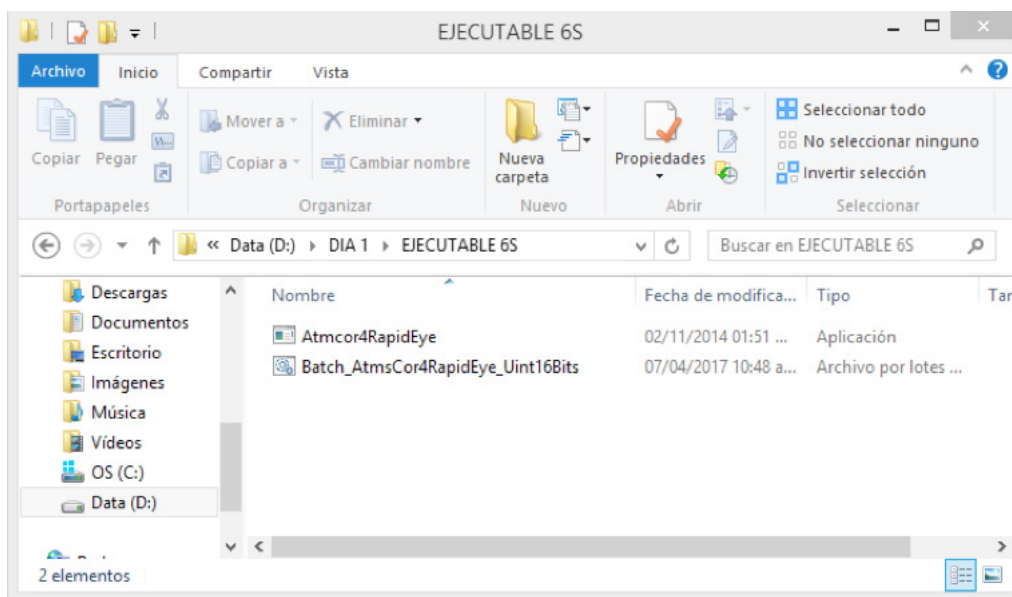


Figura 5. Carpeta “EJECUTABLE 6S”

En la carpeta “RESULTADOS” se encuentran las subcarpetas donde se guardarán los resultados del procesamiento de imágenes (Figura 6).

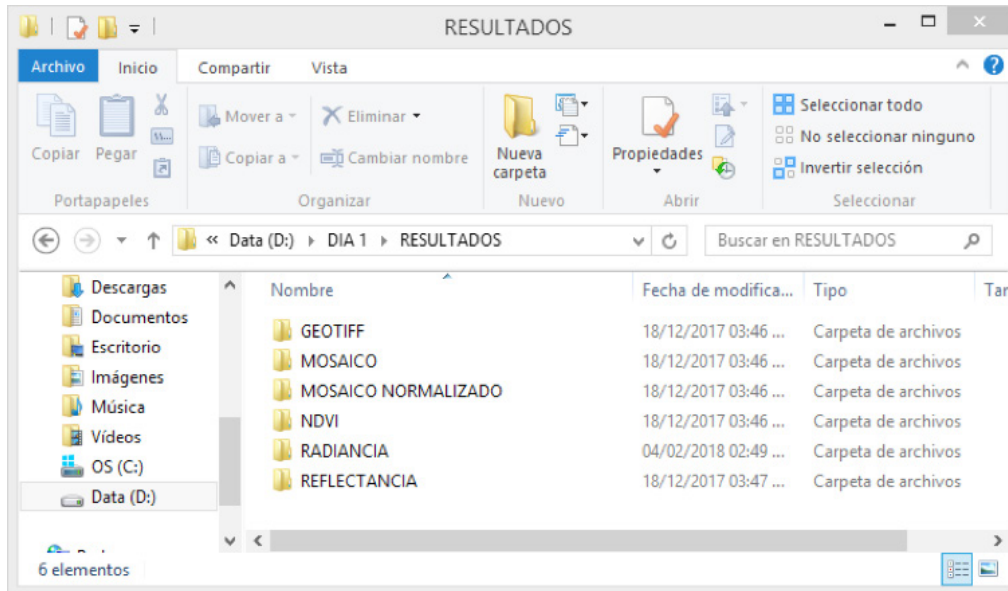


Figura 6. Carpeta “RESULTADOS”

## VIII. PROCESAMIENTO DE IMÁGENES

### 1. TRANSFORMACIÓN DE LOS ND A VALORES DE RADIANCIA

Mediante un código elaborado en IDL se leerá las imágenes RapidEye a partir del metadato. Luego se convertirá los valores del nivel digital y/o número digital de la imagen a valores físicos de radiancia espectral en el tope de la atmósfera. Para ello, seleccione el ícono desde el menú de inicio de Windows (se recomienda usar una versión de IDL superior a 8.0 en el sistema operativo de 64 bits).

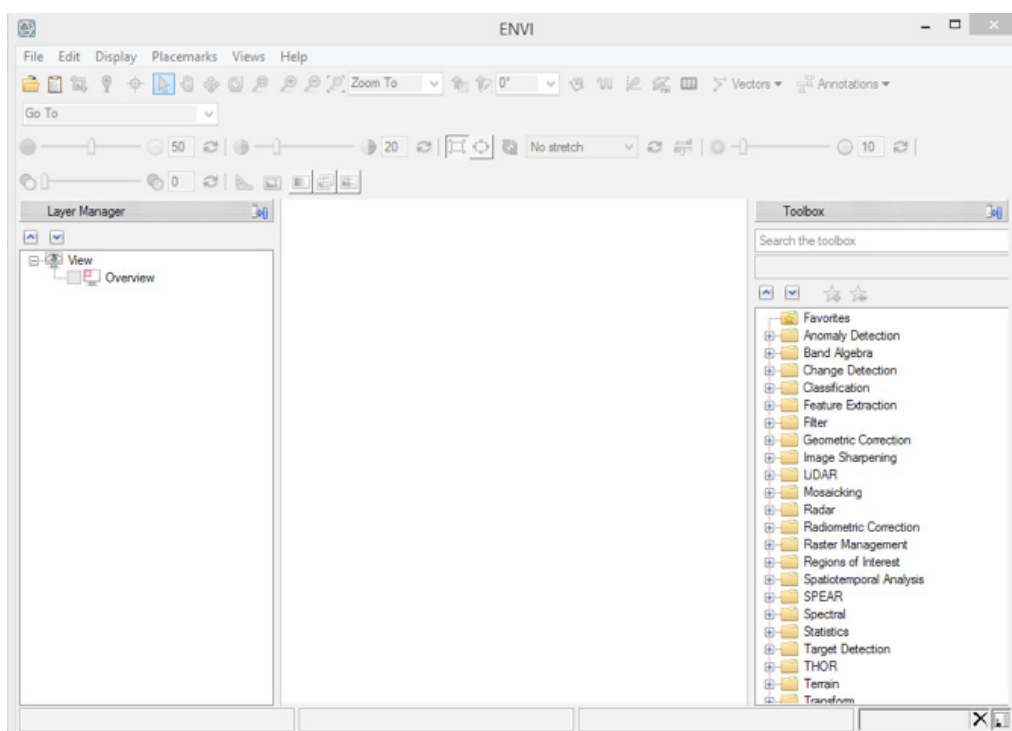
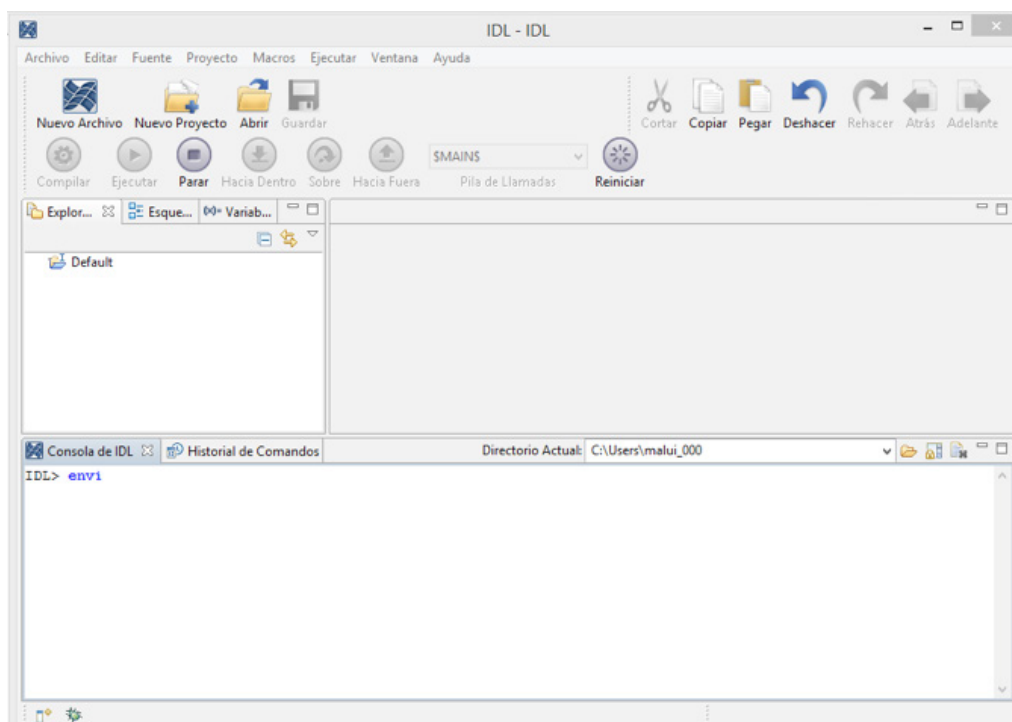


Figura 7. Apertura de ENVI 5.3 + IDL 8.5

En la Figura 7 se muestra la ventana del entorno de ENVI y del IDL. Sobre el IDL seleccione Archivo → Abrir y ubíquese en la carpeta “CÓDIGOS DE CALIBRACIÓN” y apertura el código “RADIANCIA\_RAPIDEYE.pro” (Figura 8).

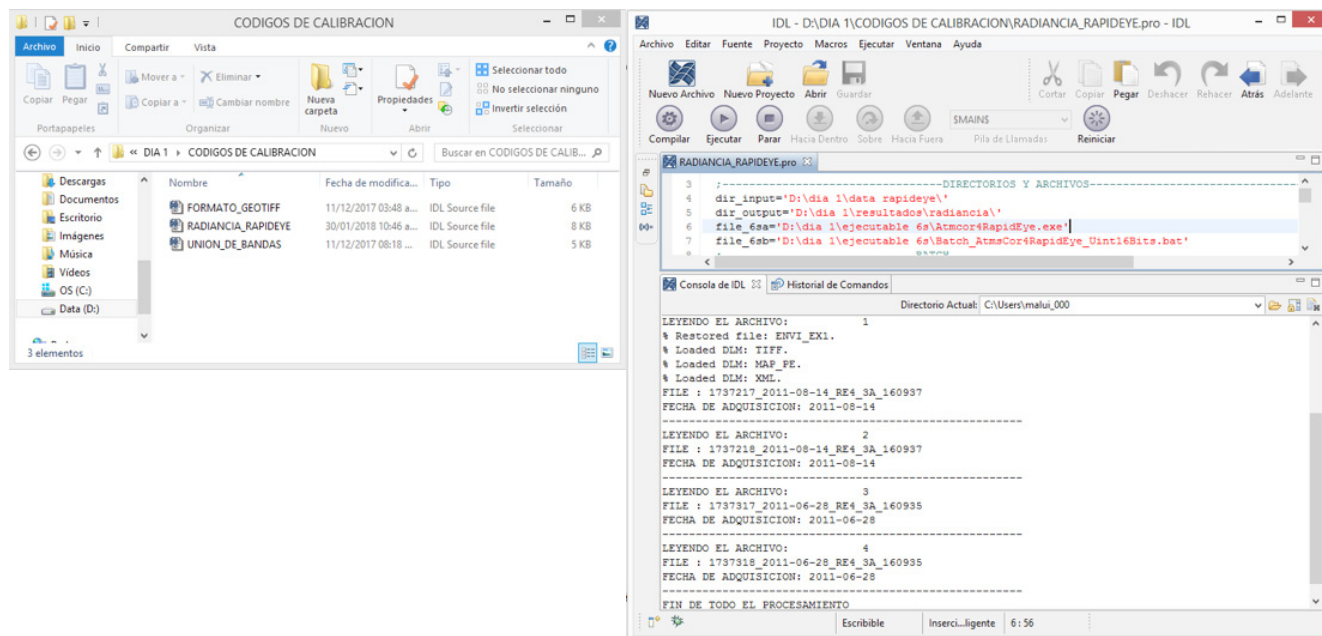


Figura 8. Apertura del código RADIANCIA\_RAPIDEYE.pro

En el código RADIANCIA\_RAPIDEYE.pro seleccione la ruta en donde se encuentran las imágenes RapidEye, los ejecutables de la corrección atmosférica y la carpeta en donde se guardarán los resultados (Tabla 2).

Tabla 2. Ruta de trabajo

Sintaxis	Directorio de trabajo
dir_input	Carpeta de las imágenes RapidEye (Carpeta Data RapidEye)
dir_output	Directorio de salida de los resultados (Carpeta Radiancia)
file_6sa	Ejecutable de la corrección atmosférica (Carpeta Ejecutable 6s)
file_6sb	Ejecutable de la corrección atmosférica (Carpeta Ejecutable 6s)

De la ventana de IDL compile y luego ejecute el código. Al compilar el código se iniciará el cálculo de la radiancia de las bandas de RapidEye, los valores de la radiancia estarán multiplicados por un factor de escala 100, debido a que el ejecutable de la corrección atmosférica requiere que la imagen de radiancia esté aplicado por el factor 100. Este código lee el metadato de las imágenes RapidEye la cual se encuentra en el formato “.xml”. En la Figura 9 se detalla los datos más importantes del metadato de la imagen 1737217\_2011-08-14\_RE4\_3A\_160937.

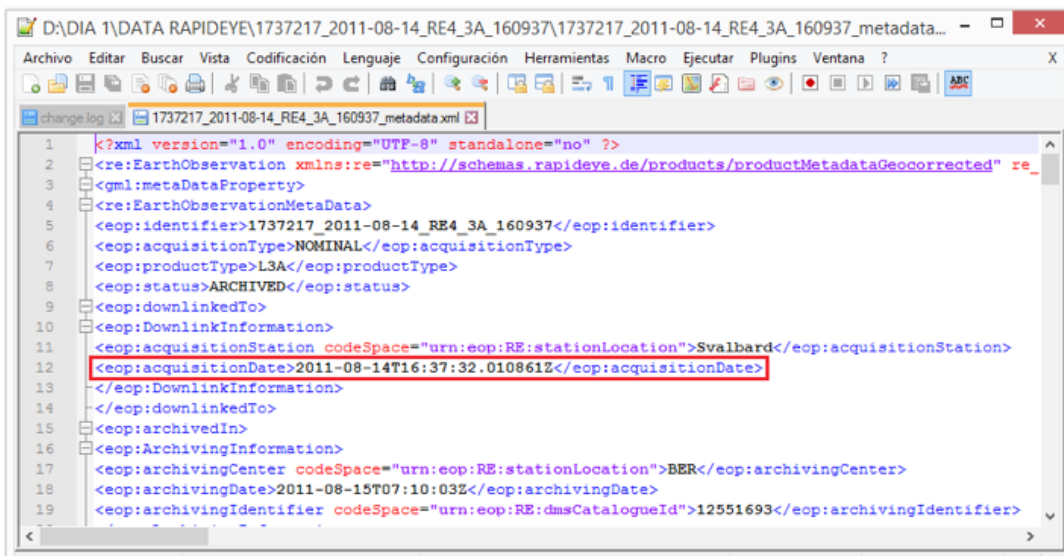


Figura 9a. Información de la fecha de adquisición de la imagen

En la Figura 9b se muestra los ángulos de elevación solar y azimuth relativo, que son importantes para la corrección atmosférica.

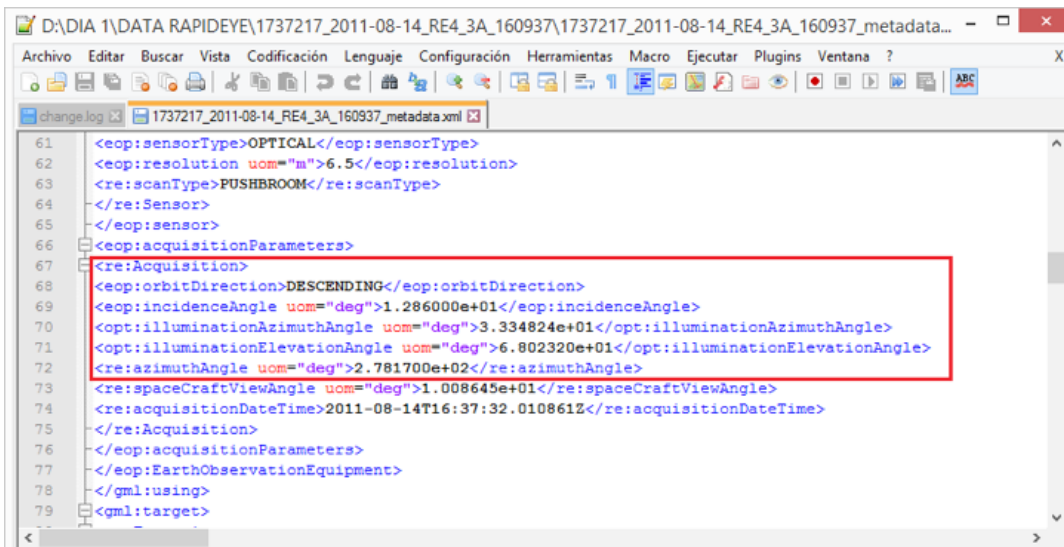
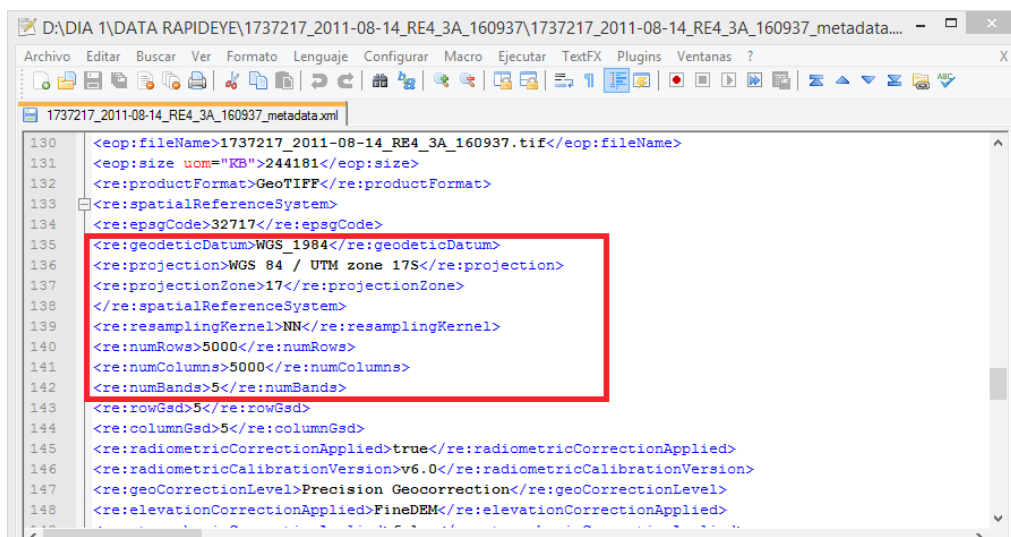


Figura 9b. Información de los ángulos.



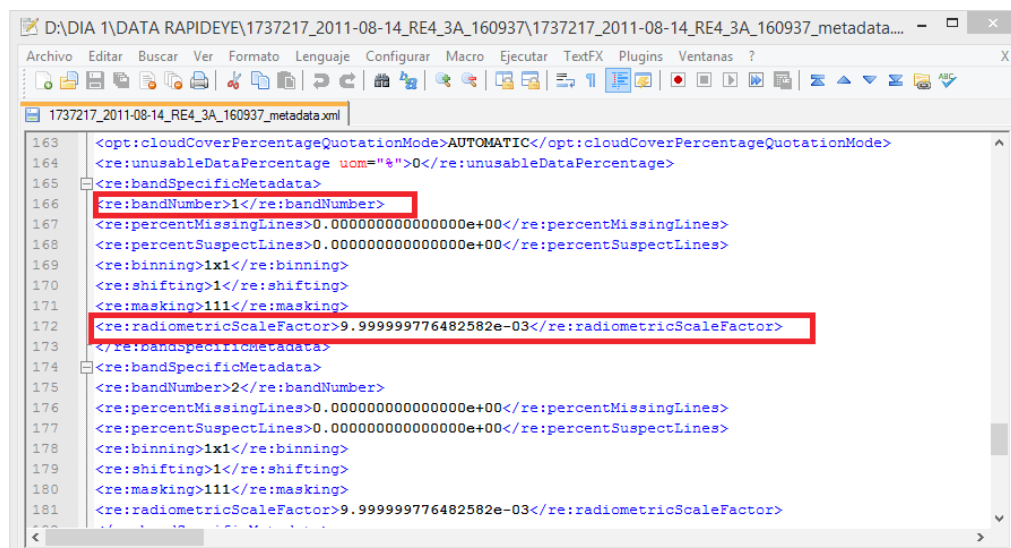
En la Figura 9c se observa que la imagen tiene 5000 filas y 5000 columnas, con datum WGS 84 zona 17 S.



```
130 <eop:fileName>1737217_2011-08-14_RE4_3A_160937.tif</eop:fileName>
131 <eop:size uom="KB">244181</eop:size>
132 <re:productFormat>GeoTIFF</re:productFormat>
133 <re:spatialReferenceSystem>
134 <re:epsgCode>32717</re:epsgCode>
135 <re:geodeticDatum>WGS_1984</re:geodeticDatum>
136 <re:projection>WGS 84 / UTM zone 17S</re:projection>
137 <re:projectionZone>17</re:projectionZone>
138 </re:spatialReferenceSystem>
139 <re:resamplingKernel>NN</re:resamplingKernel>
140 <re:numRows>5000</re:numRows>
141 <re:numColumns>5000</re:numColumns>
142 <re:numBands>5</re:numBands>
143 <re:rowGsd>5</re:rowGsd>
144 <re:columnGsd>5</re:columnGsd>
145 <re:radiometricCorrectionApplied>true</re:radiometricCorrectionApplied>
146 <re:radiometricCalibrationVersion>v6.0</re:radiometricCalibrationVersion>
147 <re:geoCorrectionLevel>Precision Geocorrection</re:geoCorrectionLevel>
148 <re:elevationCorrectionApplied>FineDEM</re:elevationCorrectionApplied>
```

Figura 9c. Información de la dimensión de la imagen, Datum y proyección

En la Figura 9d se observa el coeficiente de calibración radiométrica para la banda 1, cuyo coeficiente es 9.99999776482582e-03.



```
163 <opt:cloudCoverPercentageQuotationMode>AUTOMATIC</opt:cloudCoverPercentageQuotationMode>
164 <re:unusableDataPercentage uom="%">0</re:unusableDataPercentage>
165 <re:bandSpecificMetadata>
166 <re:bandNumber>1</re:bandNumber>
167 <re:percentMissingLines>0.000000000000000e+00</re:percentMissingLines>
168 <re:percentSuspectLines>0.000000000000000e+00</re:percentSuspectLines>
169 <re:binning>1x1</re:binning>
170 <re:shifting>1</re:shifting>
171 <re:masking>111</re:masking>
172 <re:radiometricScaleFactor>9.99999776482582e-03</re:radiometricScaleFactor>
173 </re:bandSpecificMetadata>
174 <re:bandSpecificMetadata>
175 <re:bandNumber>2</re:bandNumber>
176 <re:percentMissingLines>0.000000000000000e+00</re:percentMissingLines>
177 <re:percentSuspectLines>0.000000000000000e+00</re:percentSuspectLines>
178 <re:binning>1x1</re:binning>
179 <re:shifting>1</re:shifting>
180 <re:masking>111</re:masking>
181 <re:radiometricScaleFactor>9.99999776482582e-03</re:radiometricScaleFactor>
```

Figura 9d. Coeficiente de calibración de la banda 1 de RapidEye

Después de haber ejecutado el código aparecerá un aviso en la consola de IDL “FIN DE TODO EL PROCESAMIENTO” (Figura 10).

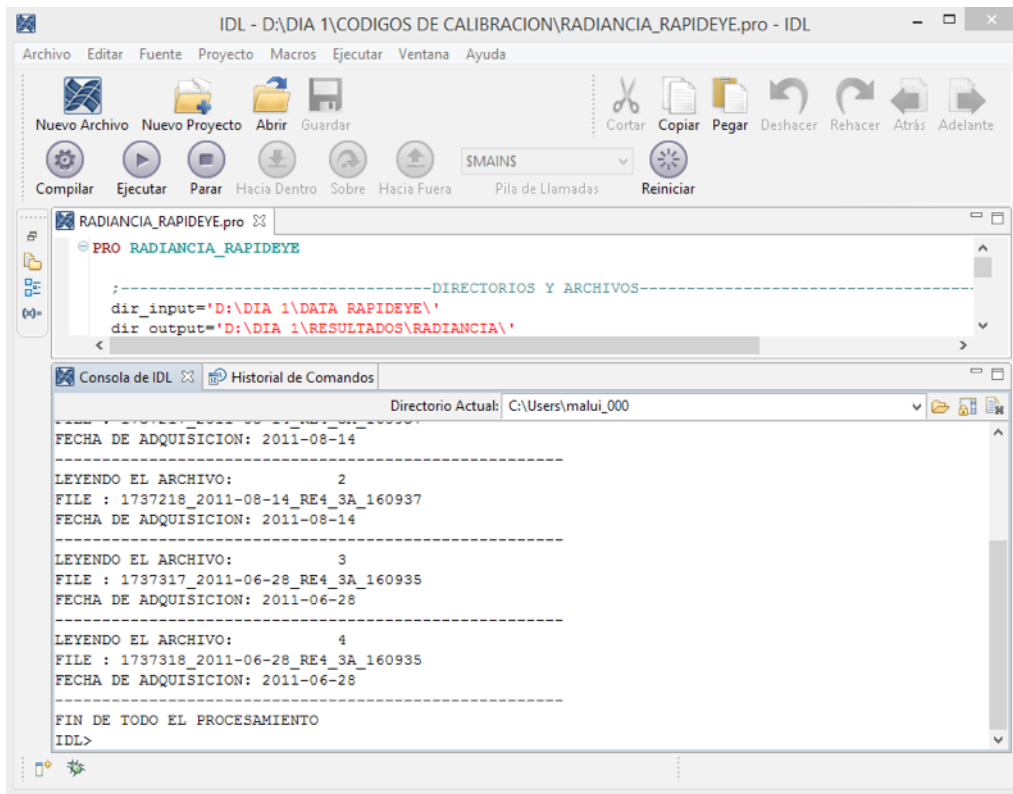


Figura 10. Fin del procesamiento de la radiancia

Ingrese a la carpeta de RADIANCIA y encontrará las imágenes calibradas en valores de radiancia espectral (Figura 11).

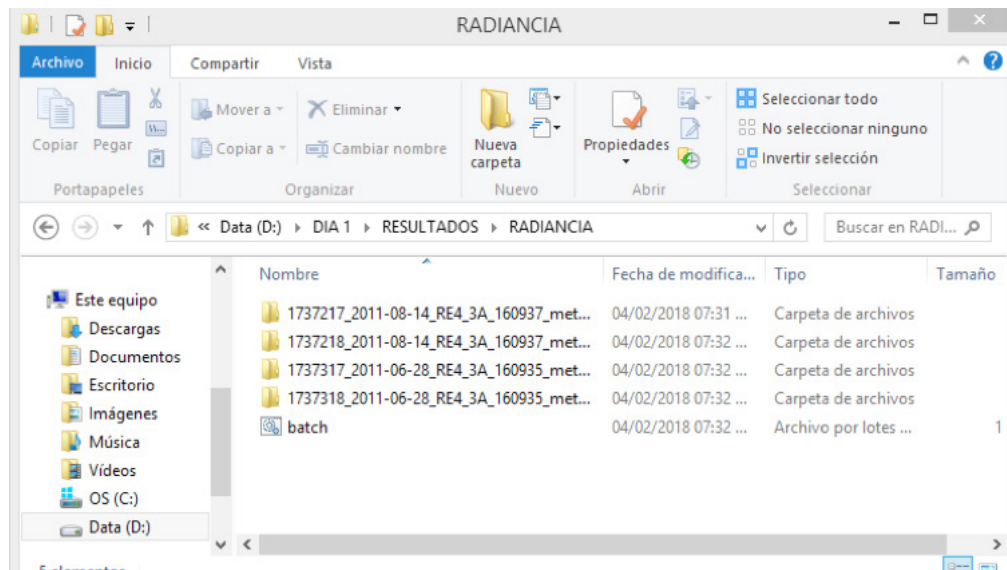


Figura 11. Imágenes RapidEye calibradas a valores de radiancia

En la misma carpeta, por ejemplo, ingrese a la subcarpeta "1737117\_2011-08-14\_RE4\_3A\_160937\_metadata" y encontrará 22 archivos como se muestra en la Figura 12.


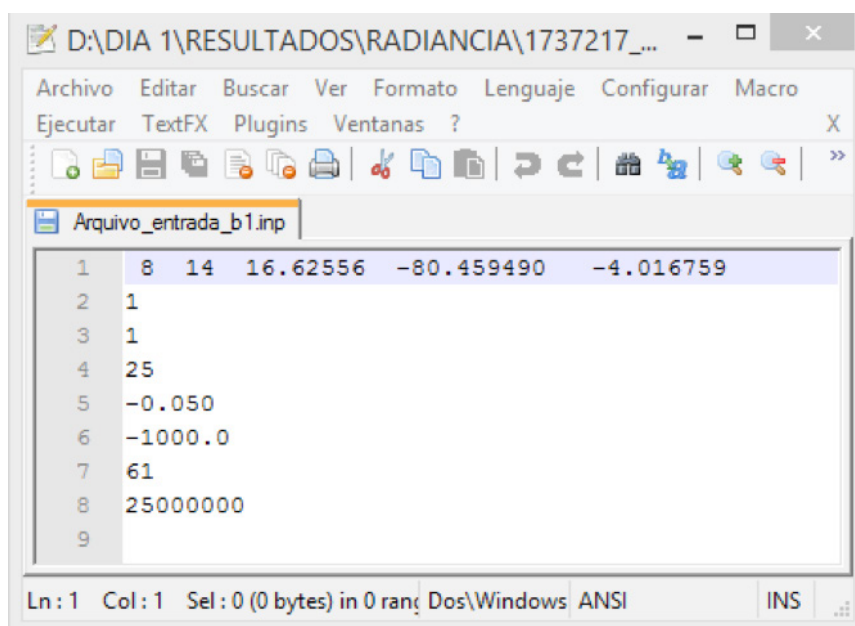


Figura 12. Archivos del proceso de la radiancia

En la Figura 12 se muestra las bandas del 1 al 5 en radiancia de formato “Raw”, debido a que para el cálculo de la corrección atmosférica se necesita que las imágenes estén en este formato. Los archivos “hdr” son las cabeceras de cada banda, la cual contiene la información del tipo de dato de la banda número de filas y columnas. El archivo “inp” contiene las condiciones atmosféricas, por ejemplo, el archivo “Arquivo\_entrada\_b1.inp” contiene la siguiente información:



**Figura 13.** Condición atmosférica

Los parámetros de la condición atmosférica para la imagen 1737117\_2011-0814\_RE4\_3A\_160937\_metadata, como se muestra en la Figura 13, tiene las siguientes características (Tabla 3).

**Tabla 3.** Características de la condición atmosférica

VALOR	PARÁMETRO
8	mes
14	día
16.62556	Tiempo universal
-80.459490	Longitud
-4.016759	Latitud
1	Modelo atmosférico tropical
1	Modelo de aerosol continental
25	Visibilidad en km
-0.050	objetivo a 50 m sobre el nivel del mar
-1000.0	Sensor a bordo del satélite
61	Correspondencia a la banda 1
25000000	Número total de pixeles de la imagen

## 2. TRANSFORMACIÓN DE LA RADIANCIA A VALORES DE REFLECTANCIA

Una vez calibradas y transformadas todas las escenas a valores de radiancia espectral, se procederá a realizar la corrección atmosférica automática. Para ello, se debe ejecutar con doble clic el archivo “batch.bat” que se encuentra dentro de la carpeta de “RADIANCIA”.

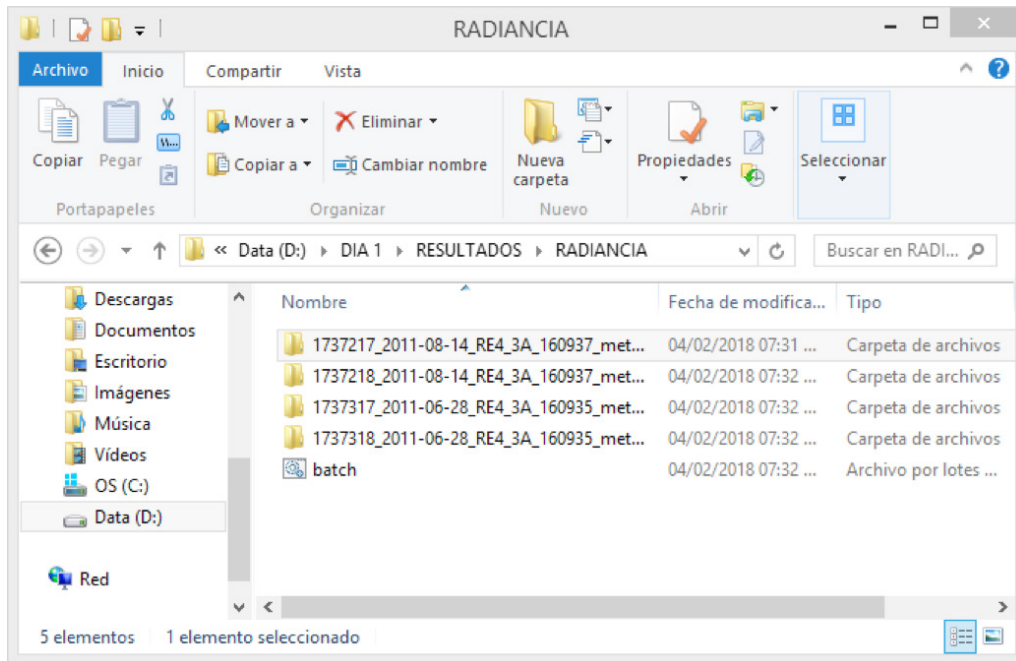


Figura 14. Modo batch

El archivo “batch” enlaza las direcciones de las carpetas en donde se calculará la reflectancia de superficie (Figura 15).

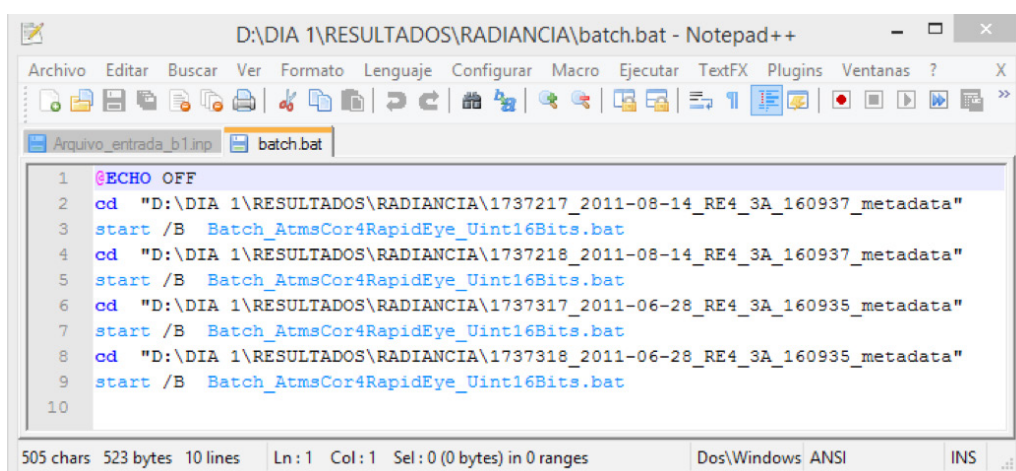


Figura 15. Procesamiento por lotes

Cuando se ejecuta el archivo “batch” se ejecutará la corrección atmosférica, la cual hará el proceso a todas las carpetas en donde contiene las imágenes en radiancia (Figura 16).

```

C:\Windows\system32\cmd.exe - Batch_AtmsCor4RapidEye_Uint16Bits.bat - Batch_AtmsCor4RapidEye_Uint16Bits.bat - Bat...
*****
6S - Second Simulation of Satellite Signal in the Solar Spectrum.

Adapted by Mauro A. Homem Antunes for atmospheric corrections of
remotely sensed images in raw format of 16 bits.
First version: August 21, 2003. Last Version: November 1st, 2012
E-mail: mauroantunes@ufrj.br

Please refer to the following papers to acknowledge the authors:

Vermote, E.F., Tanre, D., Deuze, J.L., Herman, M., and Morcrette,
J.J., (1997), Second simulation of the satellite signal in
the solar spectrum, 6S: An overview., IEEE Trans. Geosc.
and Remote Sens. 35(3):675-686.

and

Antunes, M.A.H., Gleriani, J.M., and Debiasi, P. (2012), Atmospheric
effects on vegetation indices of TM and ETM+ images from a tropical
region using the 6S model. In: Proceedings of the IEEE
IGARSS2012, Munich, 2012, pp. 6549-6552.

The code is provided as is with no implied warranty whatsoever and it is not to be sold.
*****
    
```

**Figura 16.** Corrección atmosférica

Una vez culminado el proceso de la corrección atmosférica, verificará que existe 33 archivos dentro de cada carpeta de las imágenes, de los 33 archivos encontrará las bandas de reflectancia (Tabla 4), por ejemplo, para la carpeta 1737217\_2011-0814\_RE4\_3A\_160937\_metadata.

**Tabla 4.** Características de la condición atmosférica

Orden de banda	Parámetro
2011-08-14_corrected__b1	Reflectancia
2011-08-14_corrected__b2	Reflectancia
2011-08-14_corrected__b3	Reflectancia
2011-08-14_corrected__b4	Reflectancia
2011-08-14_corrected__b5	Reflectancia




Figura 17. Archivos del procesamiento de imágenes

Como se observa en la carpeta de resultados, las bandas de reflectancia se encuentran por separado, el siguiente paso es unir las bandas en forma ascendente, según su orden de longitud de onda (0.4750  $\mu\text{m}$ , 0.5550  $\mu\text{m}$ , 0.6575  $\mu\text{m}$ , 0.7100  $\mu\text{m}$ , 0.8050).

### 3. UNIÓN DE BANDAS ESPECTRALES Y CÁLCULO DEL NDVI

Para unir las bandas o apilar, se abre el código UNION\_DE\_BANDAS.pro que se encuentra en la carpeta de CÓDIGOS DE CALIBRACIÓN (Figura 18)

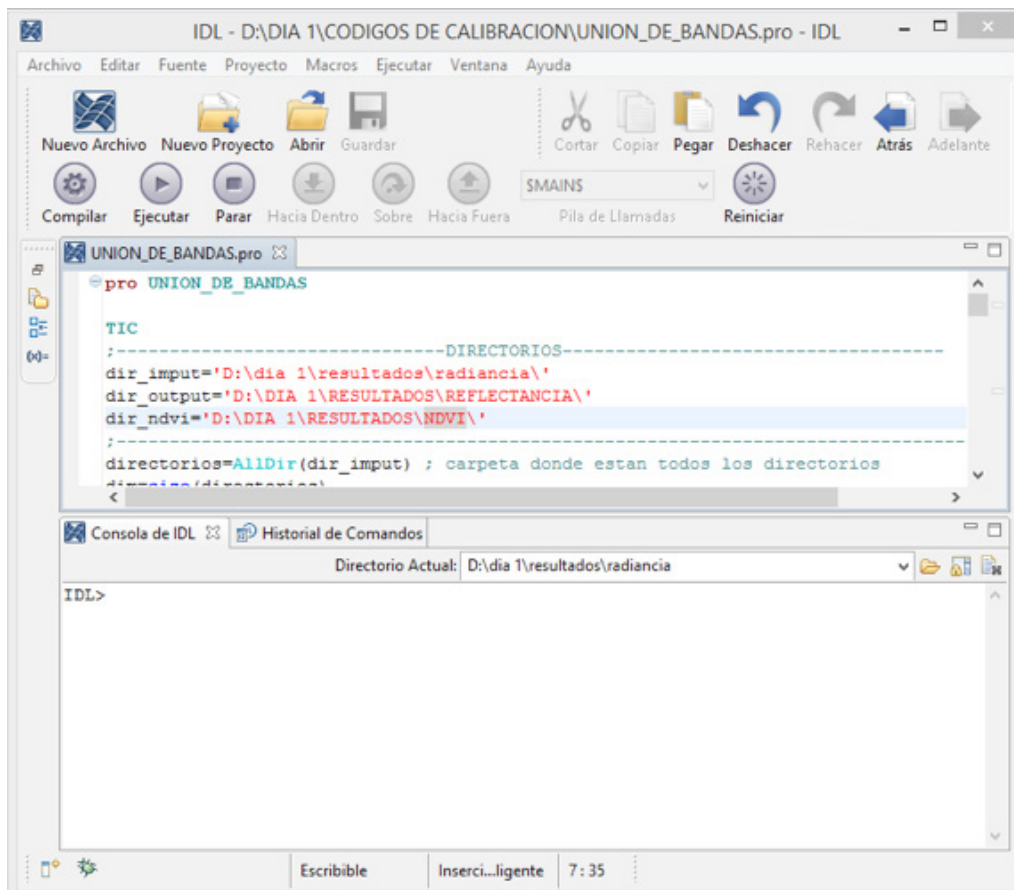


Figura 18. Código de “UNION\_DE\_BANDAS.pro”

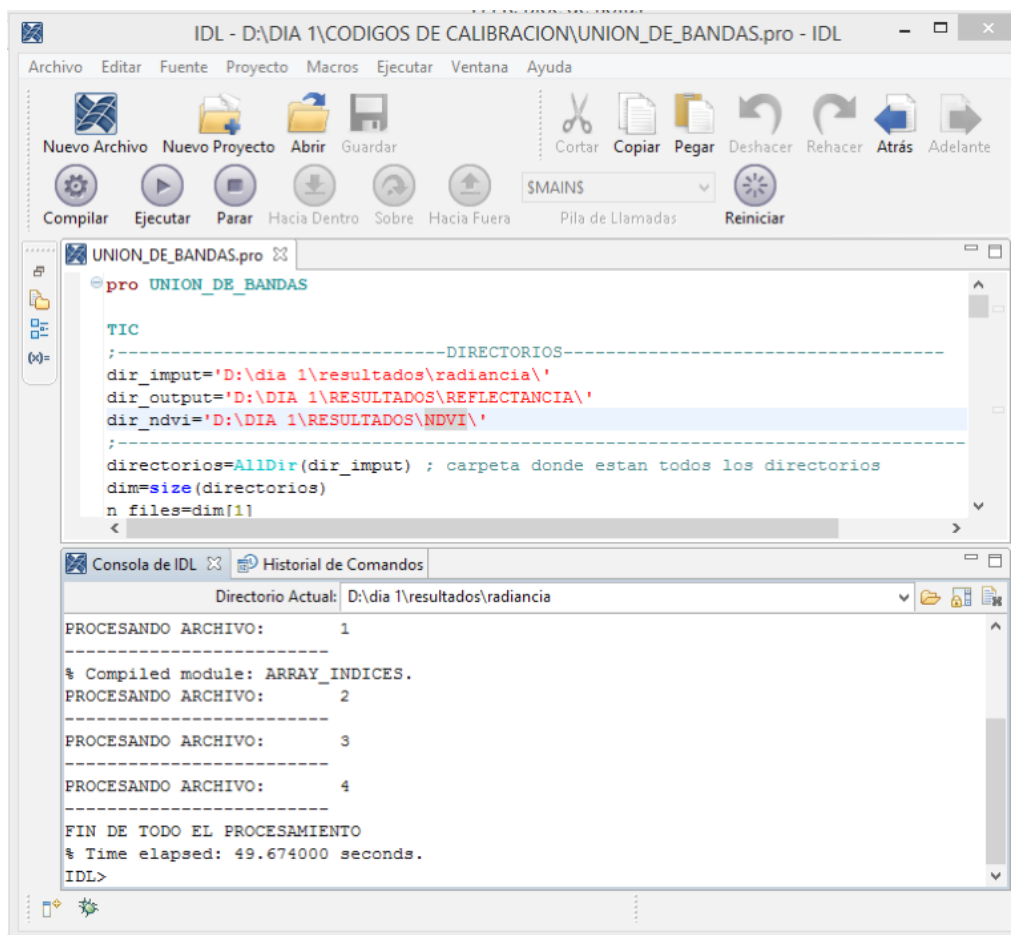
En el código UNION\_DE\_BANDAS.pro seleccione la ruta en donde se encuentran las bandas en reflectancia, la salida en donde se guardará las imágenes apiladas y el NDVI (Tabla 5).

Tabla 5. Ruta de trabajo para el proceso de apilamiento

Sintaxis	Directorio de trabajo
dir_input	Carpeta de las bandas en reflectancia
dir_output	Directorio de salida de las imágenes apiladas
dir_ndvi	Directorio de salida de las imágenes NDVI



De la ventana de IDL compile y ejecute el código. Al compilar el código se iniciará el cálculo del NDVI y el almacenamiento ordenado o apilado de bandas (Figura 19).



**Figura 19.** Procesamiento del NDVI y de la unión de bandas

Verifique en la carpeta de REFLECTANCIA (Figura 20) las imágenes apiladas, como se muestra en la Tabla 6.

**Tabla 6.** Imágenes RapidEye en reflectancia apiladas

Codificación	Parámetro
1737217_2011-08-14_RE4_3A_160937_REFLECTANCIA_SUP	Reflectancia
1737218_2011-08-14_RE4_3A_160937_REFLECTANCIA_SUP	Reflectancia
1737317_2011-06-28_RE4_3A_160935_REFLECTANCIA_SUP	Reflectancia
1737318_2011-06-28_RE4_3A_160935_REFLECTANCIA_SUP	Reflectancia

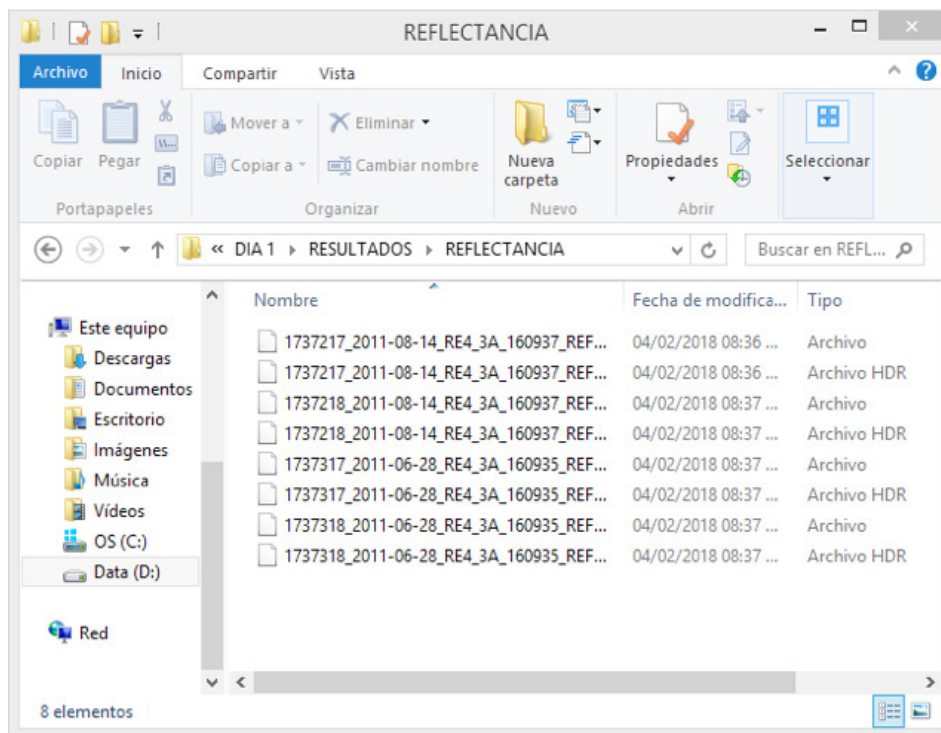


Figura 20. Imágenes RapidEye apiladas

Verifique en la carpeta de NDVI las imágenes del índice de vegetación de diferencia normalizada de las cuatro escenas de RapidEye como se muestra en la Figura 21.

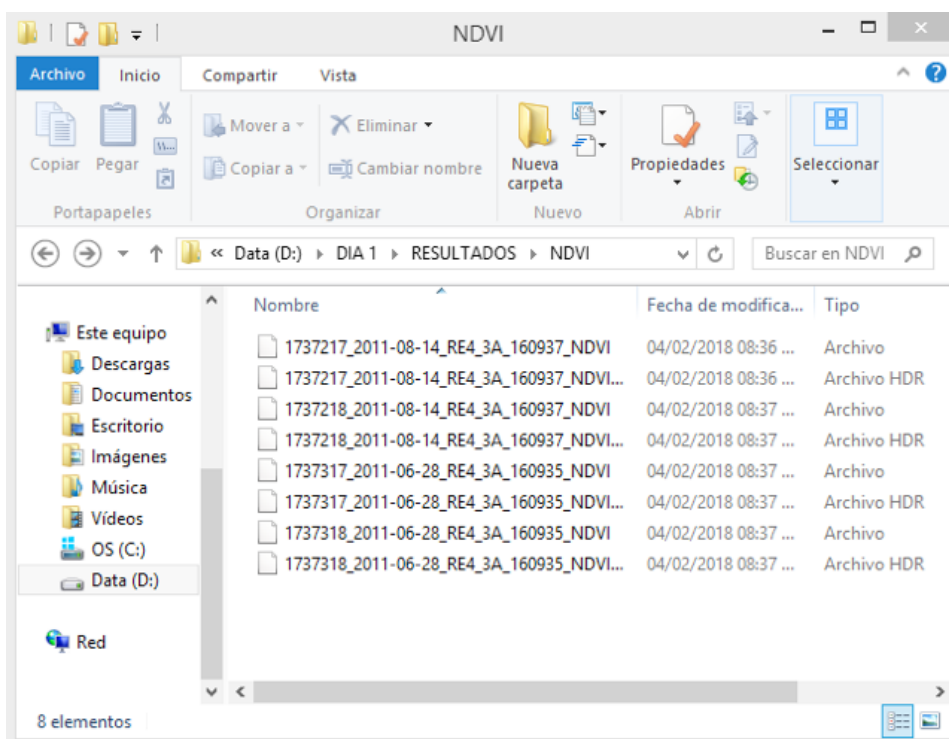


Figura 21. Imágenes NDVI derivado de la reflectancia

#### 4. ANÁLISIS ESPECTRAL DE LAS IMÁGENES RAPIDEYE

Para realizar el análisis espectral apertura el ENVI 5.3. De la barra del menú del ENVI seleccione File → Open y seleccione las imágenes RapidEye en reflectancia apilada.

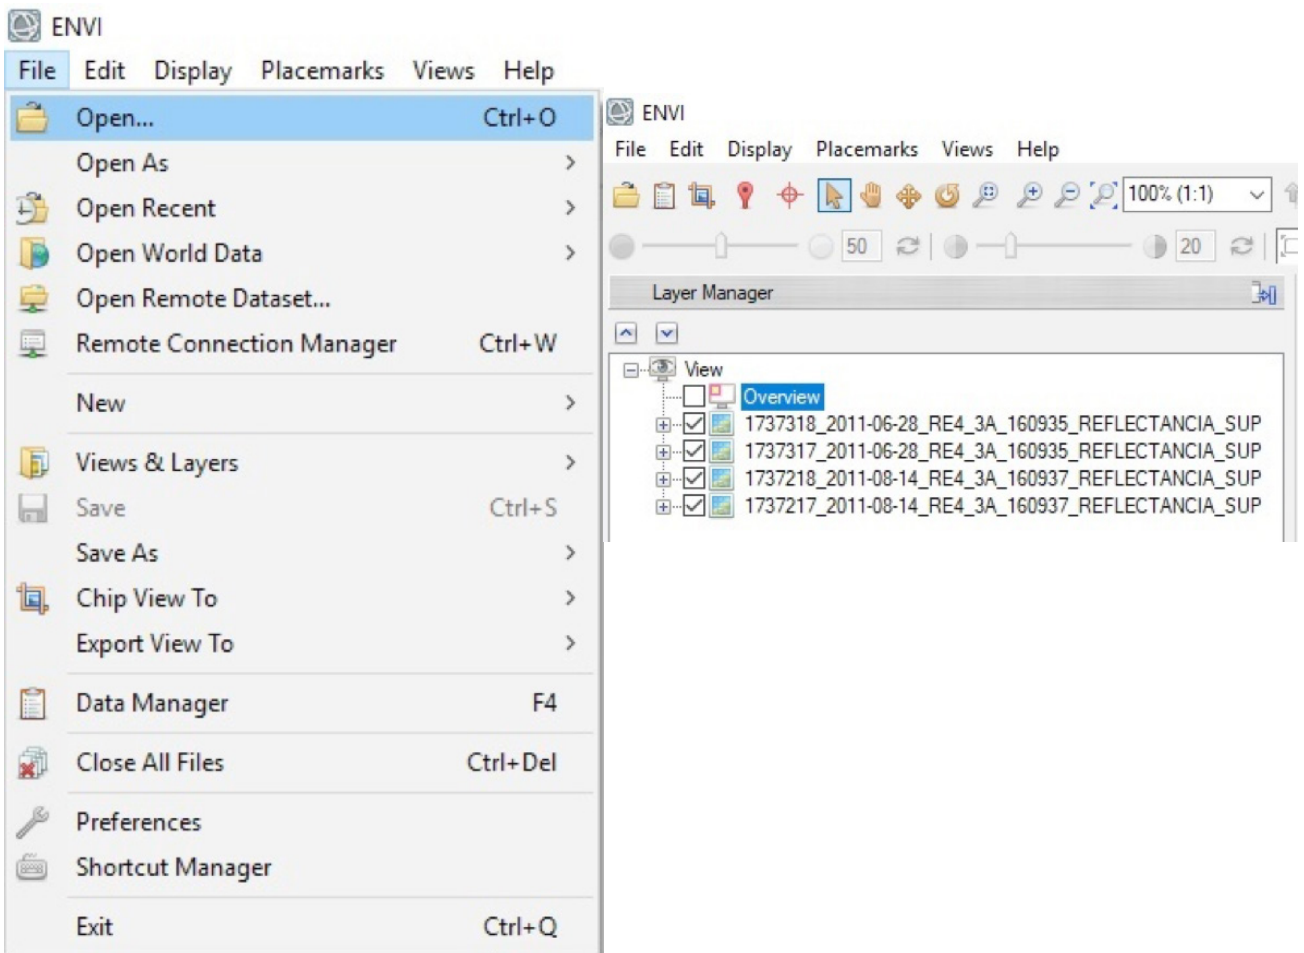


Figura 22. Apertura de las imágenes de reflectancia usando ENVI clásico

De la ventana “Layer Manager”, seleccione la imagen “1737317\_2011-06-28\_RE4\_3A\_160935\_REFLECTANCIA\_SUP” y active la herramienta “Change RGB Bands...”, combine las bandas 453. (Figura 23).


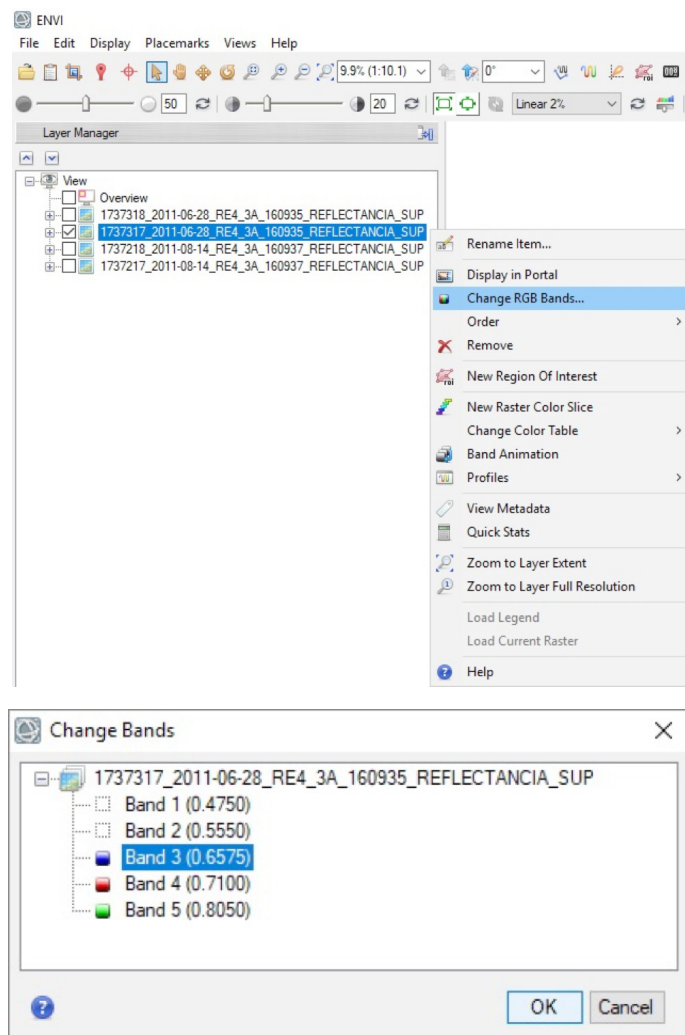
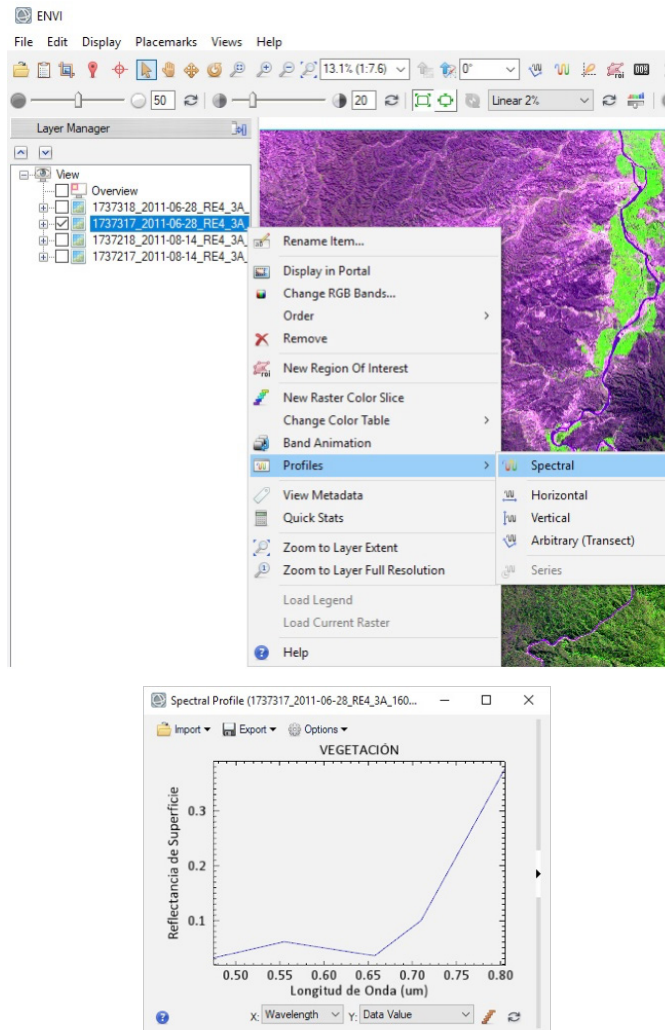


Figura 23. Apertura de las imágenes de reflectancia usando ENVI

De la ventana de la imagen seleccione clic derecho y active las herramientas “Z de la ventana “Layer Manager”, seleccione la imagen “1737317\_2011-06-28\_RE4\_3A\_160935\_REFLECTANCIA\_SUP” y active la herramienta “Profiles→Spectral”, combine las bandas 453. (Figura 24).



**Figura 24.** Apertura de la herramienta “Spectral”

Sobre la herramienta “Go To” edite los valores en Sample y Line como se muestra en la Tabla 7.

**Tabla 7.** Ubicación del píxel

Sample	Line	Tipo de cubierta
2883	868	Suelo
2887	1066	Vegetación
2912	1061	Agua

En la Figura 25 se muestran las firmas espectrales para las superficies de agua, vegetación y suelo. Se observa que la reflectancia de la superficie del agua refleja cerca del 5% o menos en el visible e infrarrojo de onda corta. El suelo muestra una reflectancia mayor que la superficie con vegetación. La reflectancia de la superficie con vegetación tiene un valor máximo en el infrarrojo cercano y muy bajo en el visible.

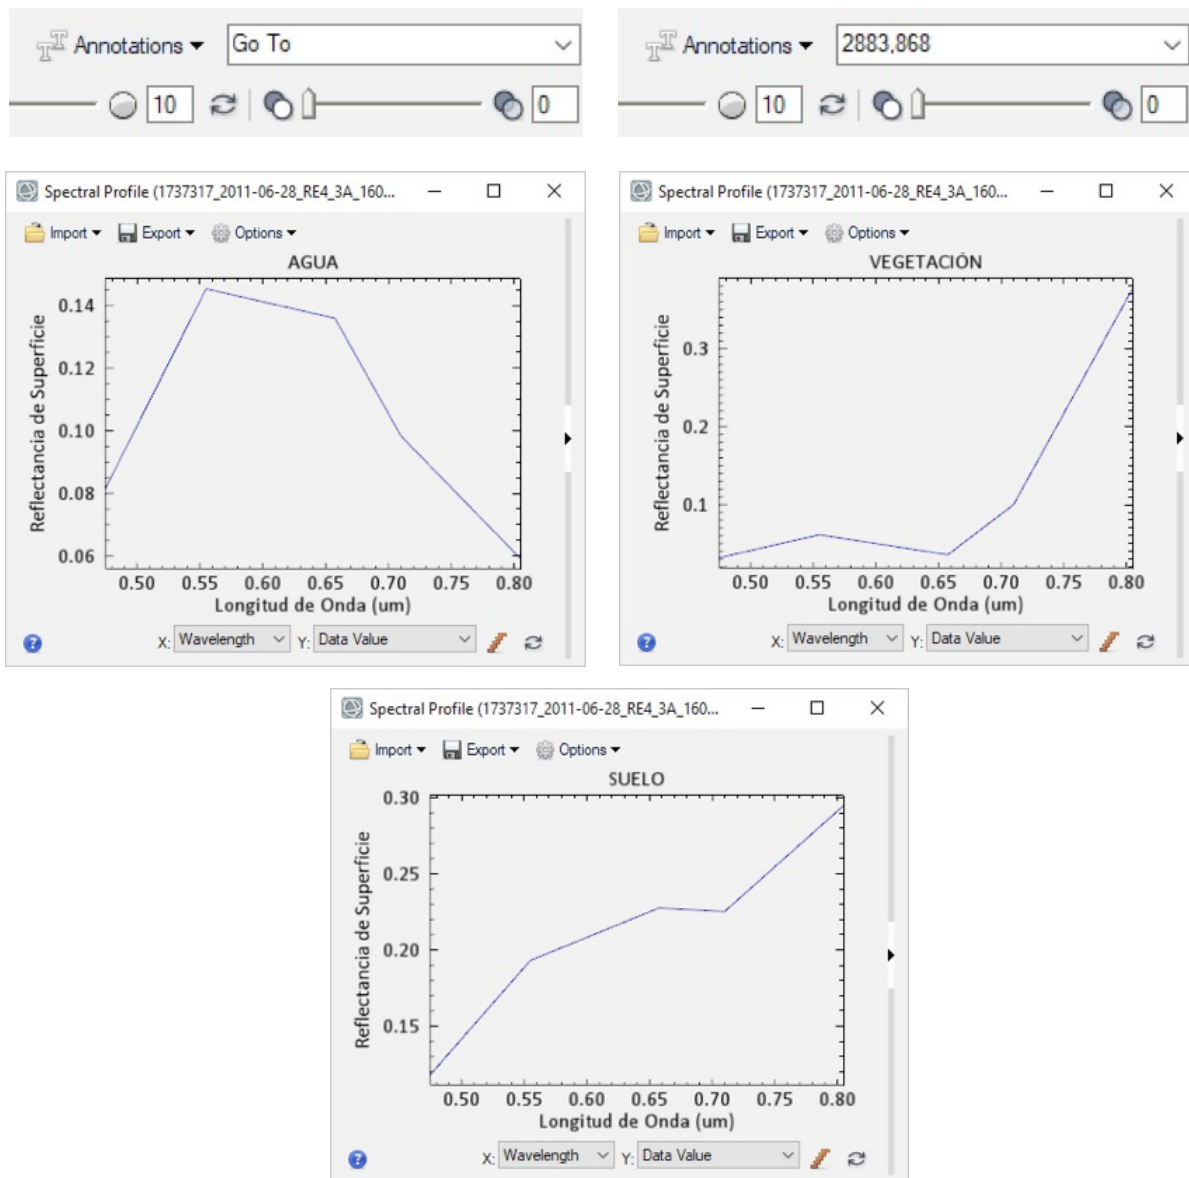


Figura 25. Análisis espectral del agua, vegetación y del suelo

## 5. MOSAICO DE IMÁGENES

Para generar el mosaico de imágenes, seleccione de la barra del menú del ENVI 5.3 la opción “Toolbox→Mosaicking→Seamless Mosaic” (Figura 26).

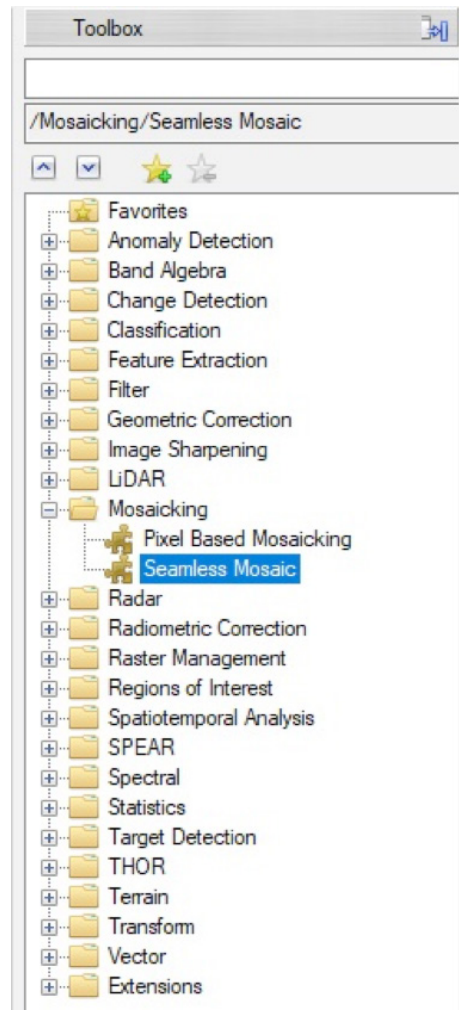


Figura 26. Apertura del módulo de mosaico

Sobre la ventana “Seamless Mosaic” active Add Scenes y seleccione las dos imágenes de fecha 2011-08-14 (Figura 27).

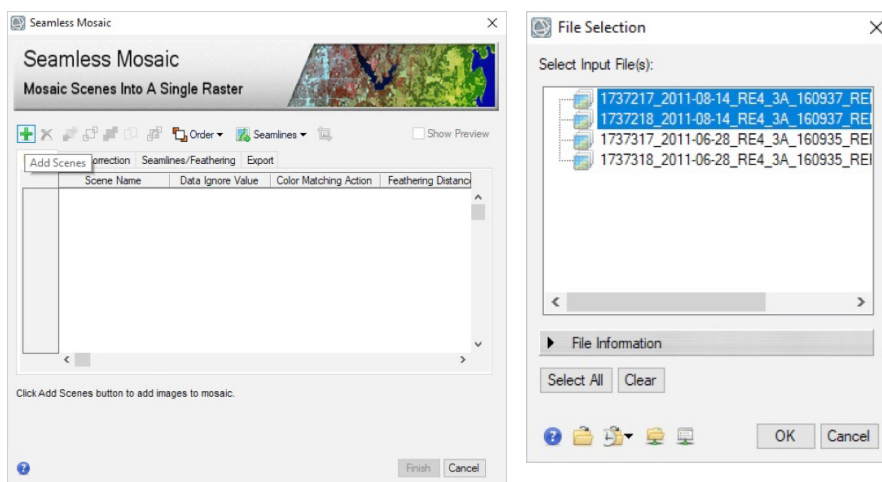


Figura 27. Selección de las imágenes para realizar el mosaico

Luego de seleccionar las dos imágenes se activarán dichas imágenes para poder realizar el mosaico (Figura 28).

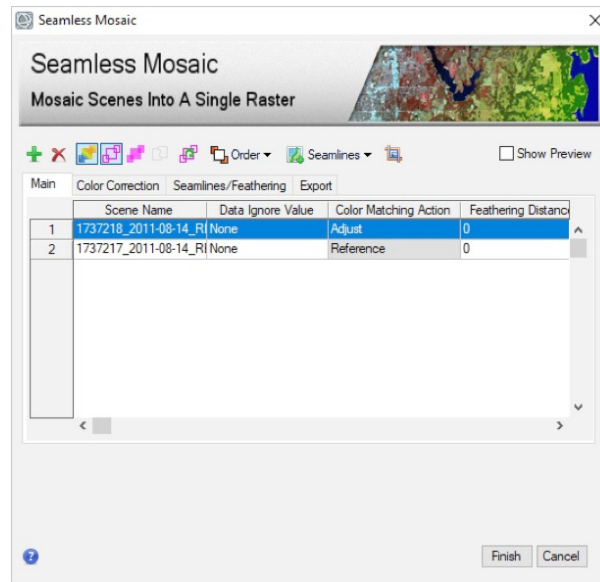


Figura 28. Activación de las imágenes para realizar el mosaico

En la siguiente ventana aparecerán las dos imágenes del año 2011-08-14. Sobre ellas seleccione Export y en “Output Background Value” edite el valor 0 y finalmente guarde el mosaico con el nombre de “2011-08-14”.

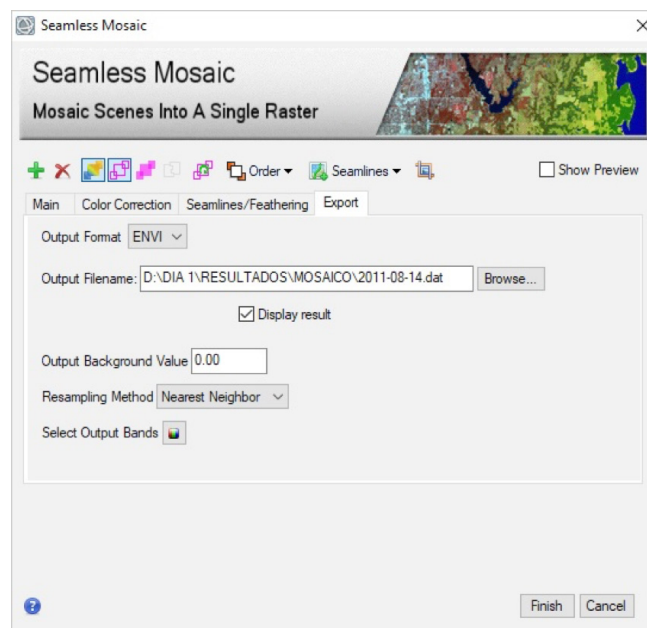


Figura 29. Selección de las imágenes para realizar el mosaico




Visualice el mosaico generado 2011-08-14 en combinación de bandas RGB: 453 (Figura 30).




**Figura 30.** Visualización del mosaico 2011-06-28

Repita los pasos anteriores y genere el mosaico de nombre 2011-06-28 (Figura 31).



**Figura 31.** Visualización del mosaico 2011-08-14

Una vez generados los mosaicos de fechas 2011-06-28 y 2011-08-14, el siguiente paso es realizar un mosaico general usando estas dos imágenes y guardarlo con el nombre de “MOSAICO”. Luego visualice el mosaico general en combinación de bandas 532 y haga una inspección visual sobre ella (Figura 32).



**Figura 32.** Visualización del mosaico en combinación de bandas 532

En la inspección visual, se observa que hay un contraste entre las dos imágenes, debido a las diferentes condiciones atmosféricas entre las fechas 2011-06-28 y 2011-08-14. Para reducir el contraste visual se deben normalizar ambas imágenes tomando como base una de ellas.

## 6. NORMALIZACIÓN DE IMÁGENES

Para realizar el proceso de normalización radiométrica relativa se emplea el software ENVI + IDL junto con los scripts de Normalización Radiométrica desarrollados por Canty (2004). Para el uso de los scripts se debe seguir el procedimiento descrito a continuación. De la carpeta CANTY seleccionar las librerías `mad_iter.pro`, `cpm_define`.

pro, gen\_eigenproblem.pro, ortho\_regress.pro y guárdelo en C:\Program Files\Exelis\IDL85\lib. De la carpeta COYOTE seleccionar las librerías cgprogressbar\_define.pro, idl\_object\_define.pro, cgerrmsg.pro, setdefaultvalue.pro y guárdelo en C:\Program Files\Exelis\IDL85\lib. De la carpeta CANTY, seleccionar los archivos PROVMEANS.dlm y PROVMEANS.x86.dll. Para seleccionar el segundo archivo se debe tomar en cuenta si el sistema operativo es de 32 o 64 bits. Cambiar el nombre de PROVMEANS.x86.dll a provmeans.dll y copiar ambos archivos en C:\Program Files\Exelis\IDL85\bin\bin.x86\_64 (Figura 33).

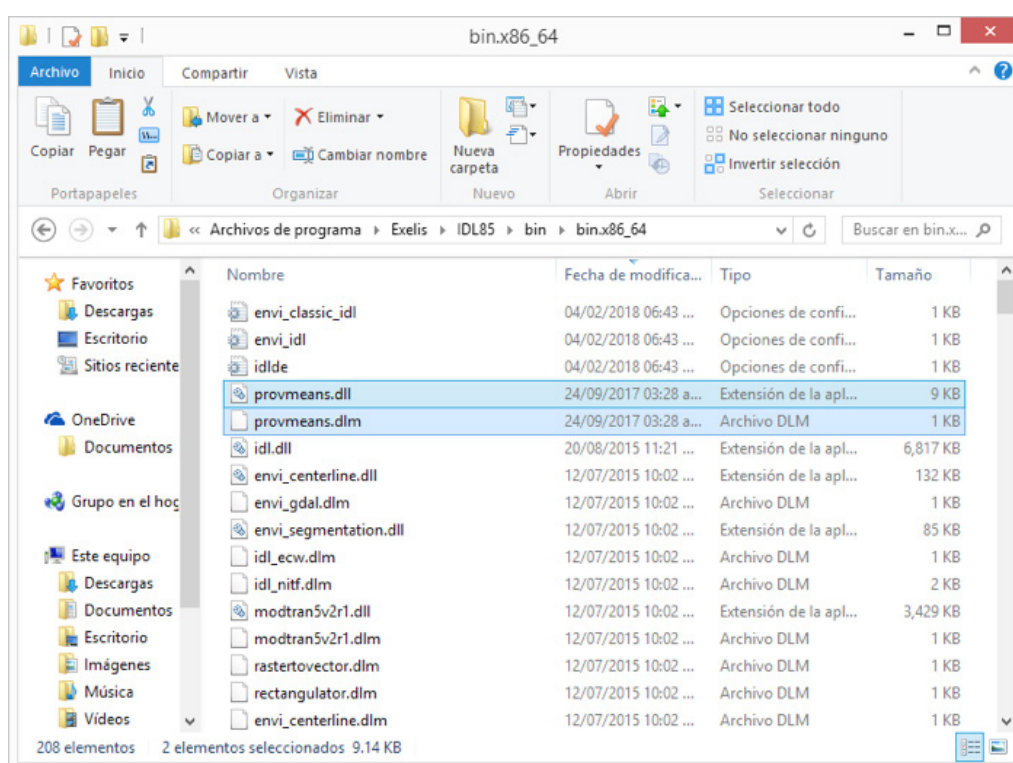


Figura 33. Visualización del mosaico en combinación de bandas 532

De la carpeta CANTY copiar los archivos MAD\_RUN.pro y RADCAL\_RUN.pro y guárdelo en el directorio C:\Program Files\Exelis\ENVI53\extensions.

A continuación, abra el ENVI 5.3 y el IDL 8.5, sobre el ENVI 5.3 Aperture las imágenes 2011-08-14 y 2011-06-28 (Figura 34)

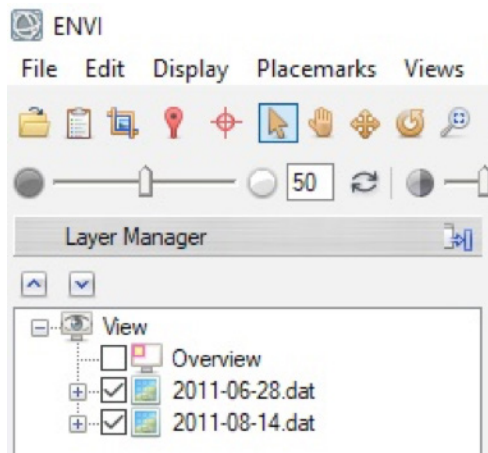


Figura 34. Apertura de las Imágenes

De la barra del menú de ENVI seleccione Raster Management → Resize Data (Figura 35).

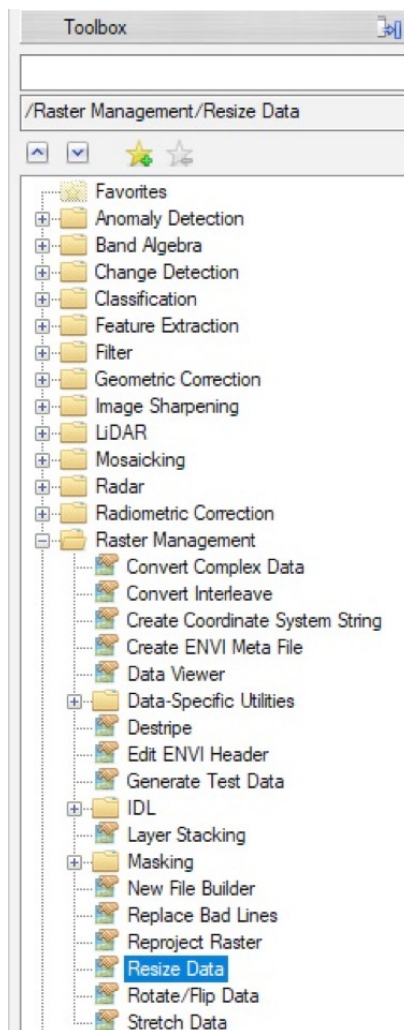


Figura 35. Función de recorte de imagen

Se abrirá la ventana Resize Data Input File, sobre ella seleccione la imagen 2011-08-14 (Figura 36).

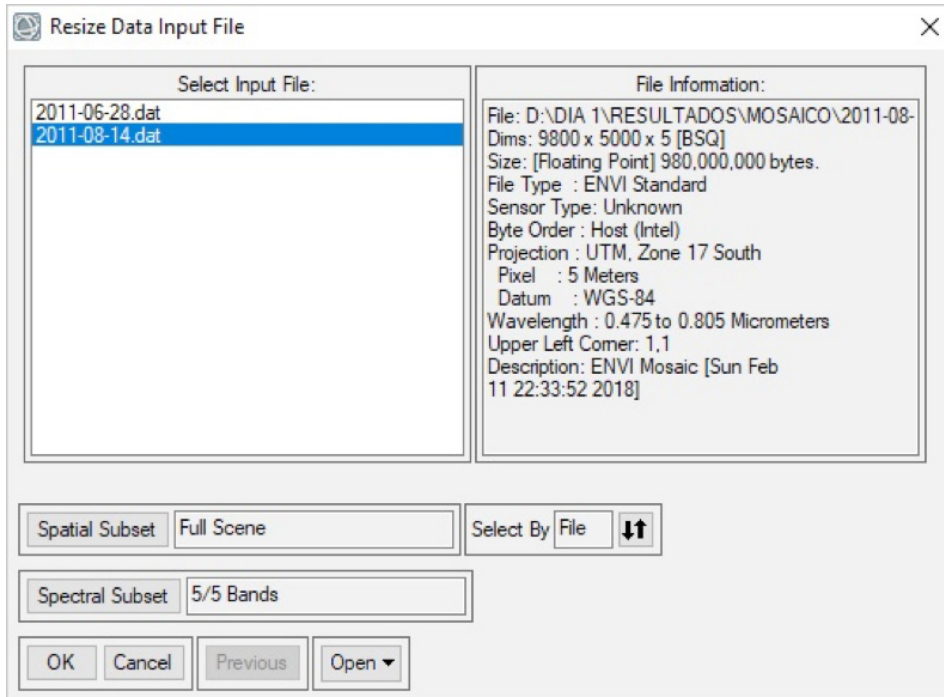


Figura 36. Selección de la imagen a ser cortada

De la ventana Resize Data Input seleccione Spatial Subset y de la ventana Select Spatial Subset seleccione File (Figura 37). Seleccione la imagen 2011-06-28 (Figura 38), la cual será la base del área de interés, ello implica que se obtendrá el área de intersección entre ambas imágenes.

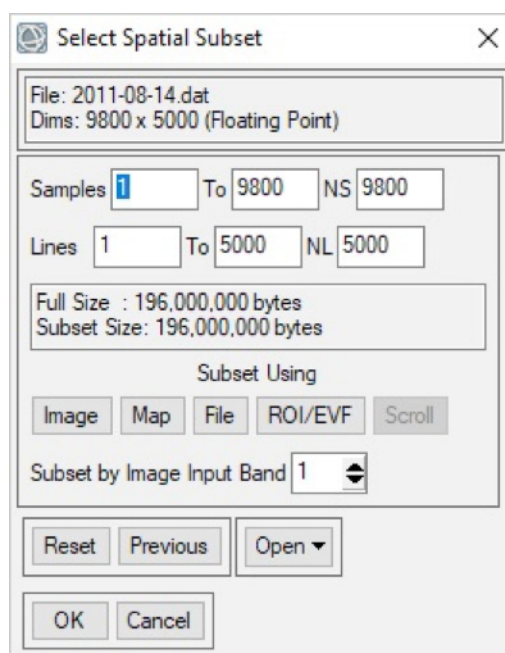


Figura 37. Selección de la imagen que será cortada




Figura 38. Selección de la imagen base

Luego guarde la imagen con el nombre de 2011-08-14-CUT (Figura 39)

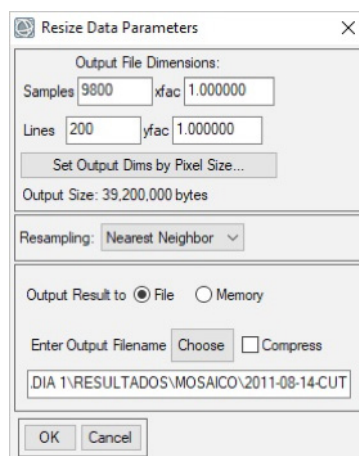


Figura 39. Salida de la imagen 2011-08-14-CUT

Repita el paso anterior para cortar la imagen 2011-06-28, tomando como base la imagen 2011-08-14 y guardarla con el nombre 2011-06-28-CUT.

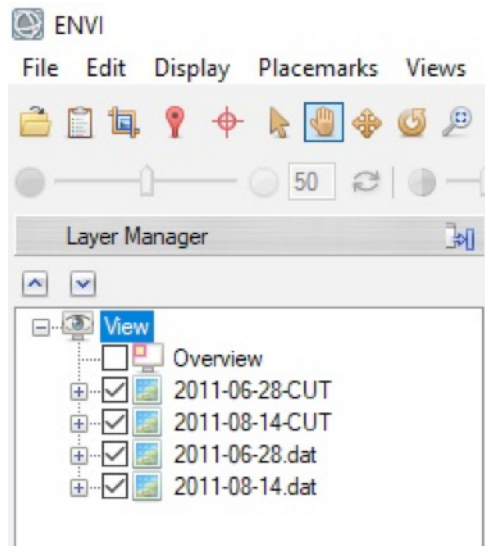


Figura 40. Salida de la imagen 2011-08-14-CUT y 2011-06-28-CUT

De la barra del menú del ENVI seleccione “Data Manager”, la cual abrirá la ventana de habilitación de las imágenes y sobre ella seleccione la banda 1 de la imagen 2011-06-28-CUT y calcule la estadística usando la herramienta Quick Stats, repita este mismo paso para la imagen 2011-06-14- CUT (Figura 41).

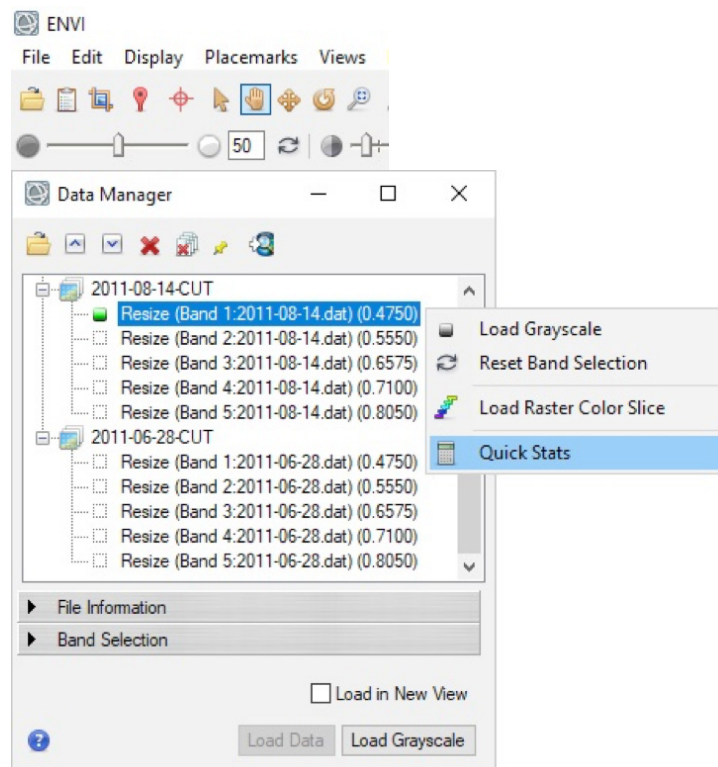


Figura 41. Cálculo de la estadística de imagen

De las ventanas de estadística de ambas imágenes se observa que el histograma de la imagen 2011-06-28-CUT presenta un promedio mayor que el histograma de la imagen 2011-08-14.

El promedio de los píxeles de la reflectancia de la banda 1 de la imagen 2011-06-28-CUT es de 0.017792 y de la imagen 2011-08-14-CUT es de 0.034641 (Figura 42).

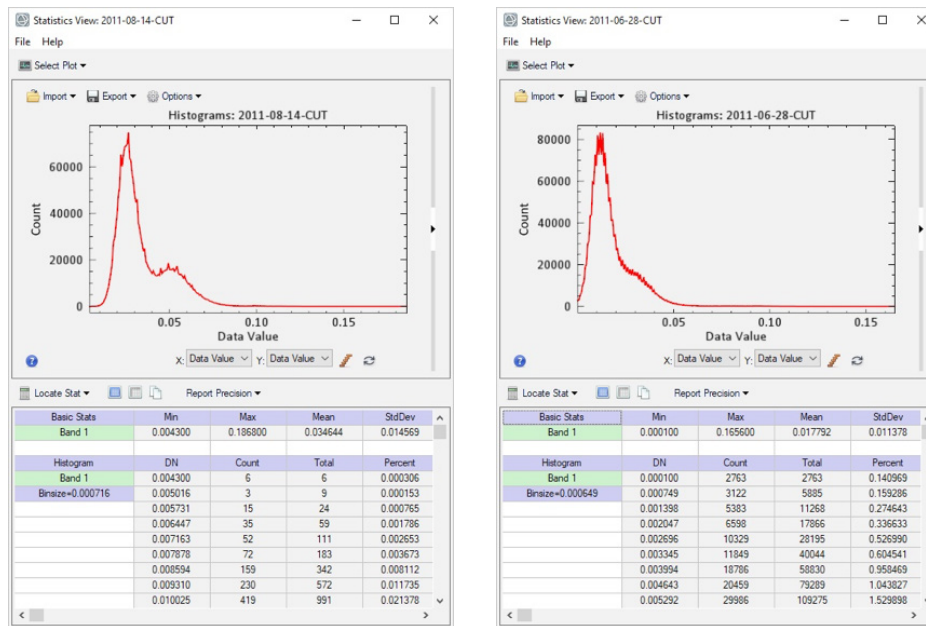


Figura 42. . Histograma de imágenes

A continuación, se usará el módulo de iMAD, para ello, en la barra de menú de ENVI, seleccione Toolbox → mad\_run (Figura 43).

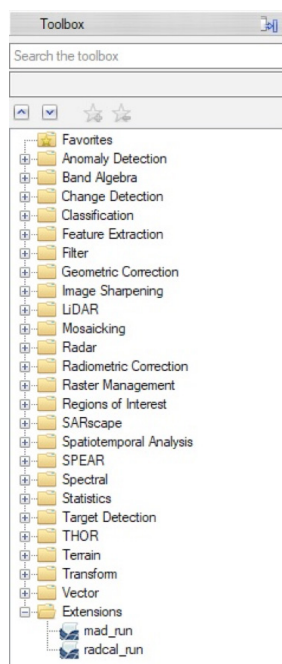


Figura 43. Selección de la herramienta mad\_run



Ingrese la primera imagen 2011-08-14-CUT, si no está en formato BIP el software hará la conversión y luego seccione 2011-06-28-CUT (Figura 44).

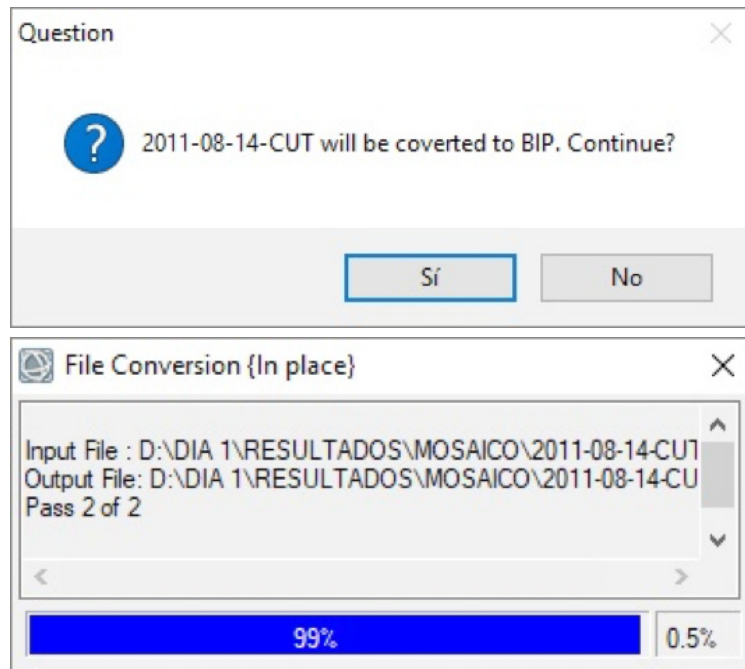


Figura 44. Transformación de BSQ a BIP

Luego de la selección de ambas imágenes se abrirá una ventana donde se seleccionará el número de píxeles que se usarán en la iteración, para este caso, seleccionaremos 100, el cual indica que se usará 100 puntos invariables entre las dos imágenes para el cálculo de la estadística. En la opción penalización, que es un parámetro que permite reducir el ruido cuando se procesan imágenes con un elevado número de bandas, este se dejará en cero, debido a que la normalización a realizar es de baja dimensión espacial (Figura 45).




Figura 45. Selección de puntos para la iteración y la penalización

Guarde los datos de la detección de alteración multivariado (MAD) con el nombre de SALIDA 1, guarde las variables canónicas (CV) con el nombre SALIDA 2, las CVs se ordenan por la correlación existente ellos en lugar del orden de la longitud de onda y finalmente guarde la estadística generada en el proceso de normalización con el nombre de SALIDA 3 (Figura 46).

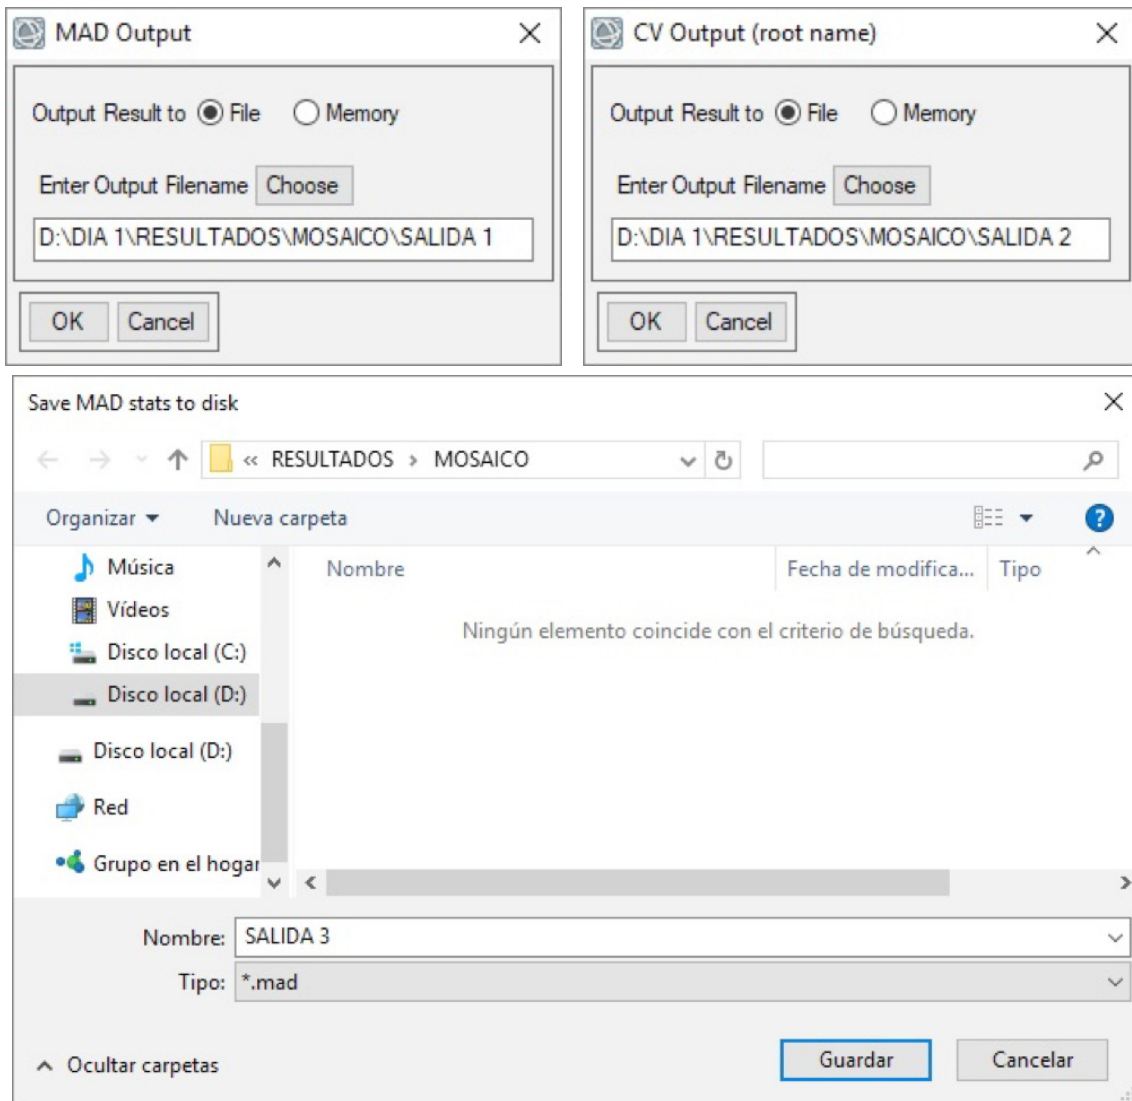


Figura 46. Salida de los archivos MAD, CV y MAD Stats

En la Figura 47 se presenta las correlaciones entre las cinco bandas de las imágenes 201108-14-CUT y 2011-06-28-CUT, alcanzando las máximas correlaciones entre sí. En la Figura 48 se muestra los archivos de salida de los archivos MAD y CV.




Figura 47. Correlación de las imágenes 2011-08-14-CUT y 2011-06-28-CUT

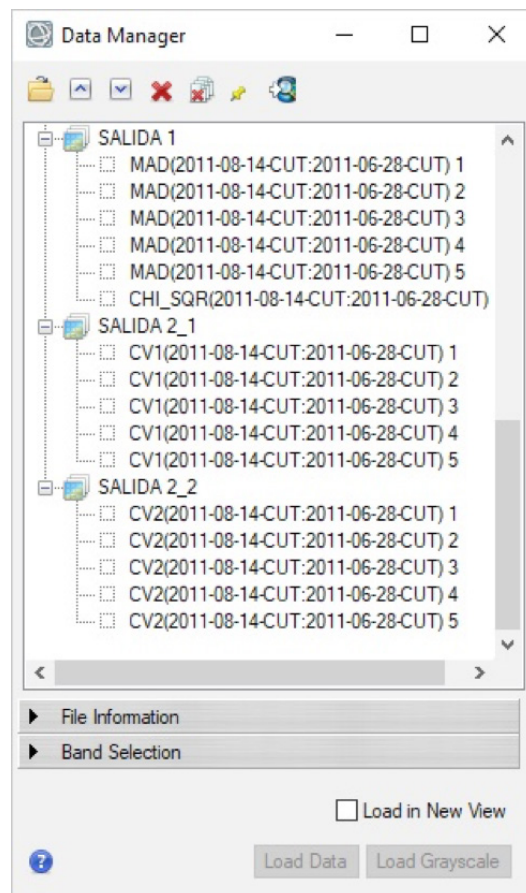


Figura 48. Salida de los archivos MAD y CV

A continuación, se usará el módulo de iMAD, para ello, en la barra de menú de ENVI, seleccione Toolbox → Extensiones → radcal\_run (Figura 49), luego seleccione la imagen base sobre la ventana Choose (Subset of) reference image y luego seleccione la imagen a ser normalizada sobre la ventana Choose (Subset of) target image (Figuras 50 y 51)

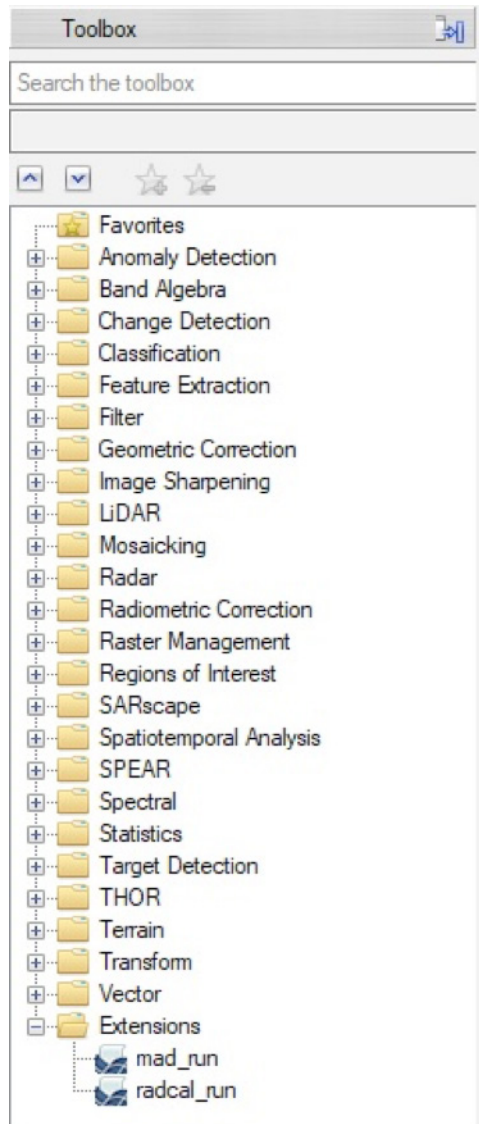


Figura 49. Activación del módulo Radiometric Normalization

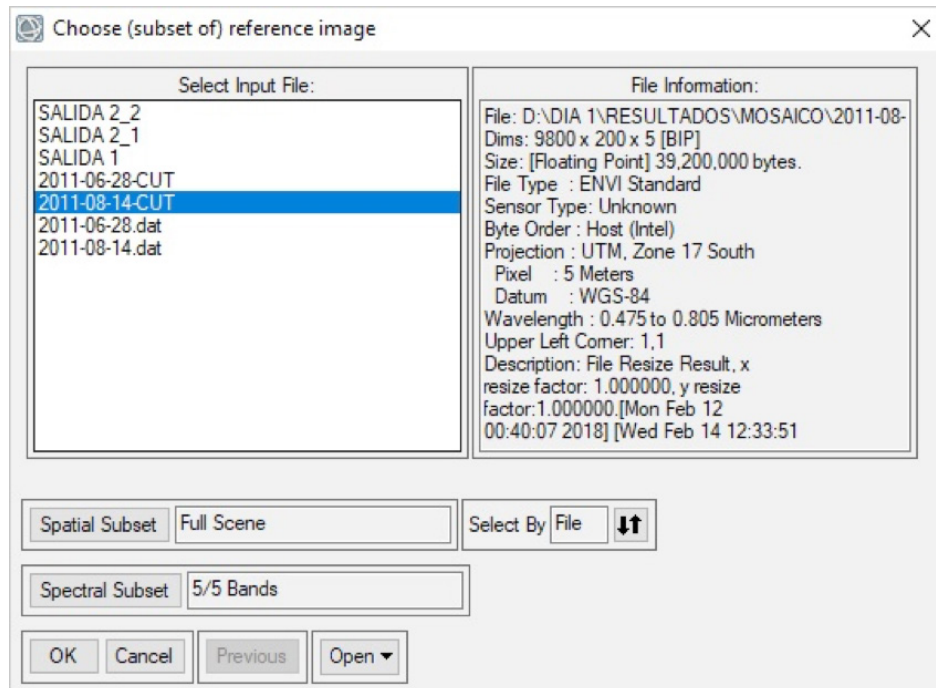


Figura 50. Selección de la imagen base 2011-08-14-cut

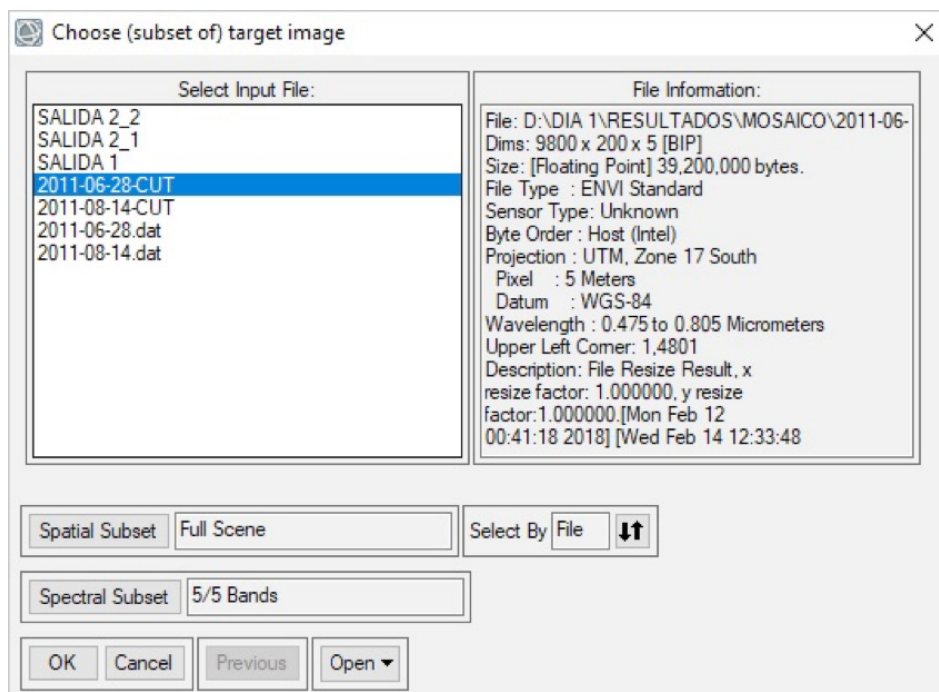


Figura 51. Selección de la imagen base 2011-06-28-cut

A continuación, seleccione la imagen chi cuadrado (Figura 52)

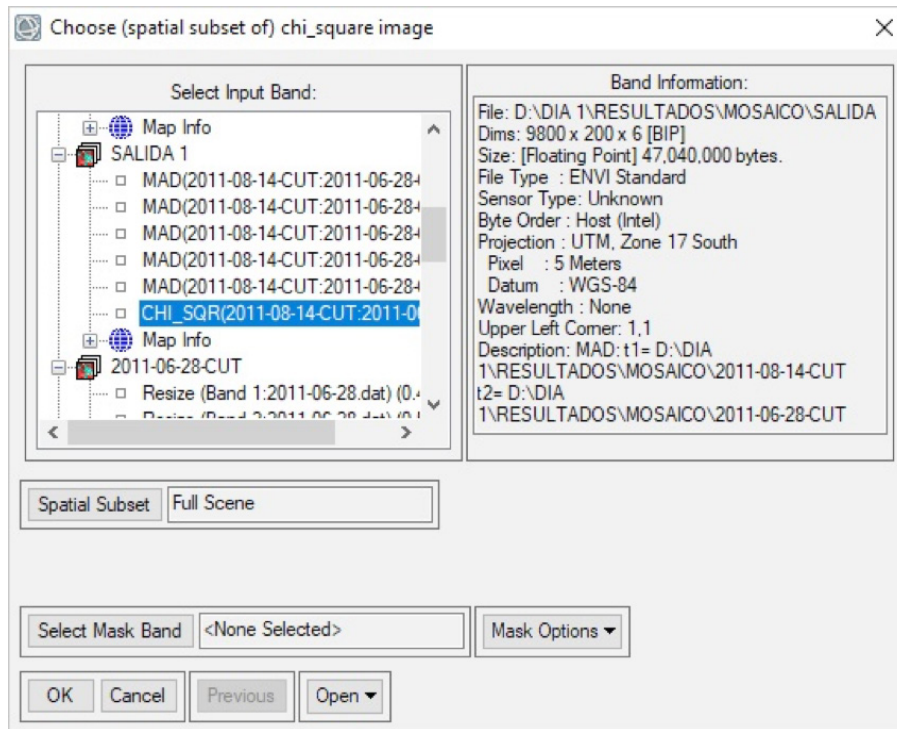


Figura 52. Selección de la imagen chi cuadrado

Una vez ejecutada la normalización se mostrará el histograma de Chi-Sqr y la selección mínima de probabilidad de no cambio que vendría a ser 95% (Figura 53).

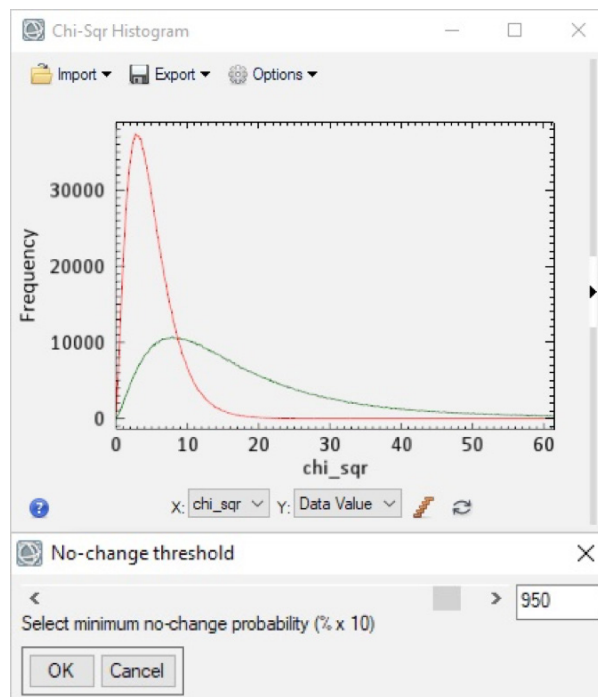


Figura 53. Selección mínima de probabilidad de no cambio

Guarde la imagen dentro de la carpeta MOSAICO con el nombre 2011-06-28-cut-N (Figura 54).

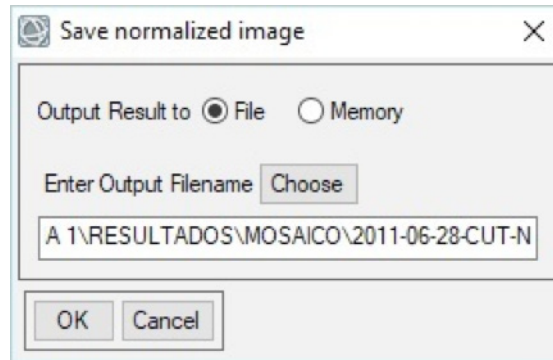


Figura 54. Salida de la imagen normalizada 2011-06-28-cut-N

Al finalizar el proceso se abrirá la ventana de nombre Question, la cual nos preguntará si queremos normalizar otra imagen. A continuación, se normalizará la imagen entera 2011-06-28, para ello seleccione dicha imagen y se guardará en la carpeta con el nombre de 2011-06-28-N (Figura 55).

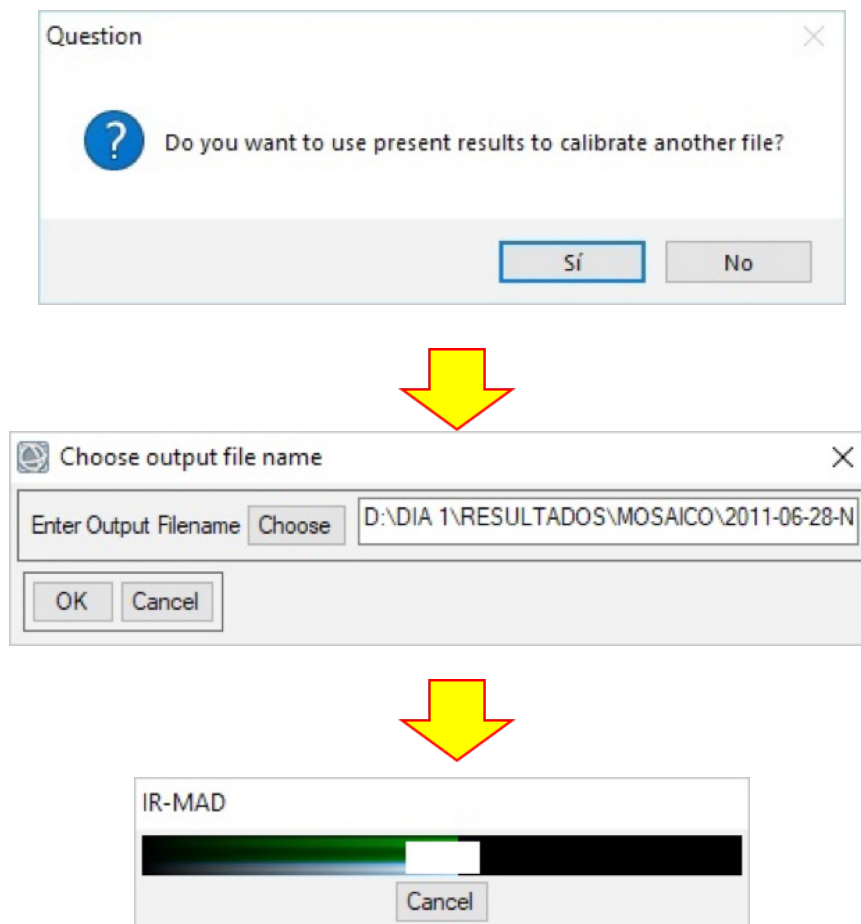


Figura 55. Salida de la imagen normalizada 2011-06-28-N

Una vez terminado el proceso de normalización se mostrará la estadística y las correlaciones como se muestra en las Figuras 56 y 57.




Figura 56. Estadística de la normalización de la imagen 2011-06-28-N

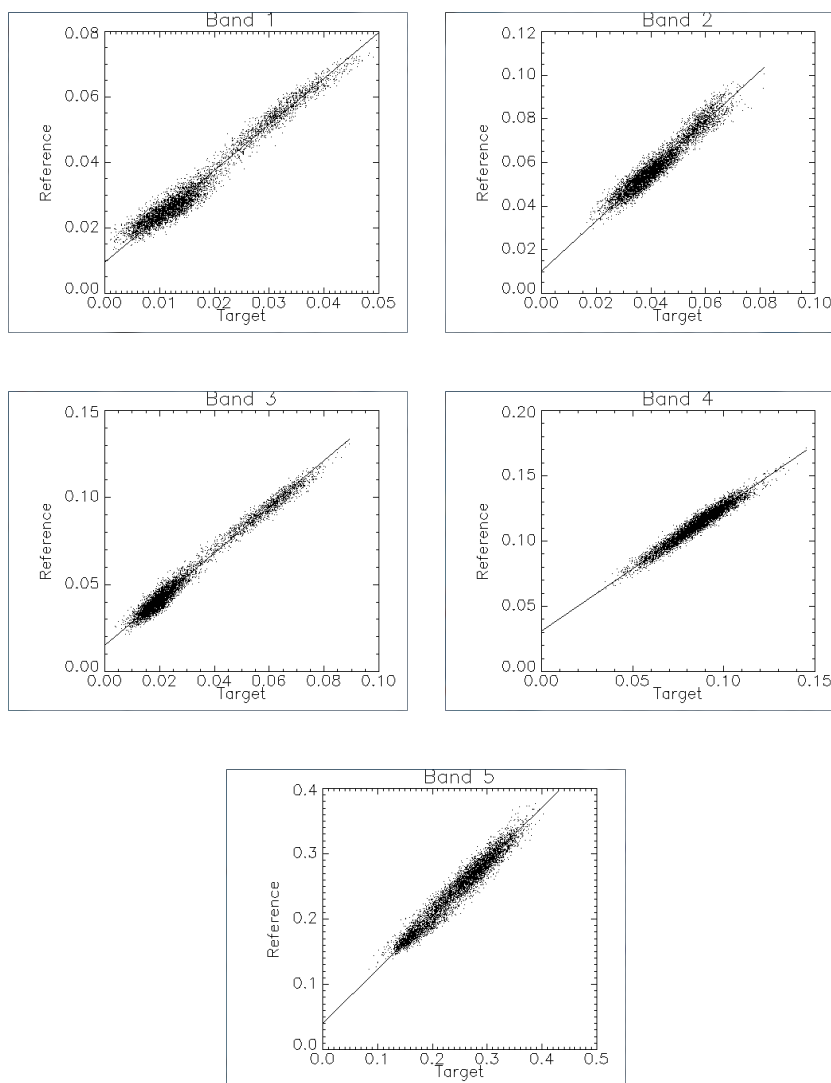



Figura 57. Correlaciones de los 5928 puntos de la imagen 2011-06-28-N



A continuación, repita los pasos anteriores sobre la unión de escenas para realizar el mosaico de imágenes entre la imagen 2011-08-14 y la imagen normalizada 201106-28-N. Guarde dentro de la carpeta MOSAICO NORMALIZADO con el nombre de MOSAICO-N.

Luego, visualice la imagen MOSAICO-N con la combinación en RGB 532. Sobre dicha imagen se observa que se redujo el contraste entre la intersección de ambas imágenes (Figura 58).



**Figura 58.** Visualización del MOSAICO-N en combinación de bandas 532

## IX. CLASIFICACIÓN DE COBERTURAS

La clasificación de las diferentes coberturas, y en especial la de las áreas agrícolas, se obtiene a partir del análisis y procesamiento digital de imágenes de mosaicos corregidos y ortorrectificados RapidEye a nivel departamental para los 24 departamentos de Perú (Figura 59). La metodología de procesamiento es de clasificación orientada a objetos (GEOBIA por sus siglas en inglés “Geospatial Object Based Image Analysis”) y se realiza sobre los 24 mosaicos departamentales, con el software ENVI. Se clasificarán las siguientes coberturas, según la metodología de clasificación Corine Land Cover Nivel 2:

- Tierras agrícolas con cultivos
- Tierras agrícolas sin cultivos
- Bosques naturales
- Pastos naturales
- Tierras eriazas
- Aguas continentales
- Bofedales
- Nubes
- Otras tierras
- No data (nubes y sombras de nubes)

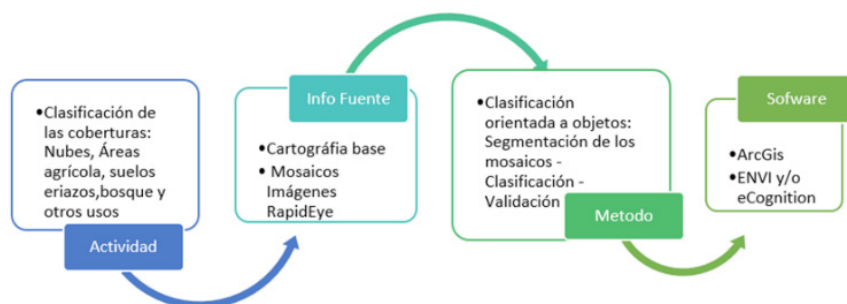


Figura 59. Proceso metodológico para la clasificación de coberturas

GEOBIA es un método de clasificación de información raster que se fundamenta en la clasificación de un conjunto de píxeles vecinos o segmentos de imagen en vez de píxeles individuales. Adicionalmente, este método de clasificación integra valores espectrales, texturales y de forma (geometría) y tamaño de los elementos que conforman la imagen sobre los cuales se aplican los algoritmos de segmentación y clasificación. Todo esto evita incurrir en los errores típicos de las clasificaciones de píxeles individuales como la clasificación de elementos de menor tamaño al objeto de estudio y superar la incapacidad de clasificar coberturas espectralmente similares, pero con diferentes texturas o formas geométricas (Qin et al. 2013; Blaschke 2010). GEOBIA está compuesto por dos pasos: la segmentación de la imagen y la clasificación de los segmentos de imagen. La clasificación GEOBIA se elaborará por medio de la herramienta Feature extraction del software ENVI 5.1. La herramienta Feature Extraction está diseñada como un flujo de trabajo que integra todas las herramientas

involucradas en la segmentación y clasificación. Por lo tanto, debe tenerse en cuenta que una vez que se comienza el primer proceso de segmentación, no se debe parar la secuencia, de lo contrario se perderán los procesos precedentes al momento en el que se suspende algún proceso. A continuación, se describen los pasos a realizar:

## 1. PREPARACIÓN DATOS DE ENTRADA (WORKFLOW)

Para comenzar a realizar una clasificación es necesario desplegar el archivo de imagen del mosaico que se desea clasificar, para esto se deben de seguir los siguientes pasos: Abrir la herramienta Feature extraction de ENVI. Tenga en cuenta que todos los pasos descritos en este manual han sido desarrollados con la herramienta Feature extraction del ENVI 5.1 (64-bit). De la barra de menú, seleccionar la opción File → Open, y buscar el archivo raster correspondiente al mosaico departamental que se desea clasificar, y abrir. Diríjase a la barra de Herramientas Toolbox. Desde Toolbox abrir la carpeta Feature Extraction → Example Based Feature extraction Workflow (Figura 60)

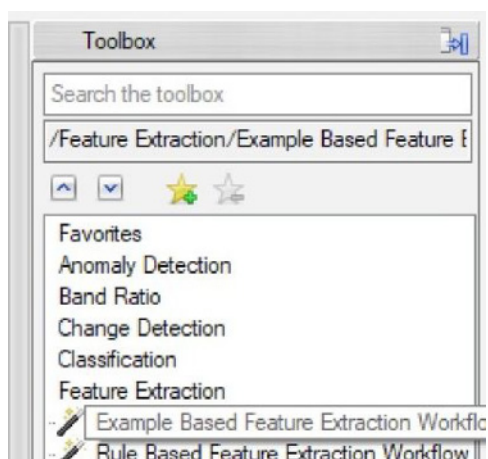


Figura 60. Example Based Feature Extraction Workflow

Después de esto aparece la siguiente ventana, la cual sirve para seleccionar el archivo de imagen (Figura 61): Input Raster: Seleccionar la imagen a procesar.

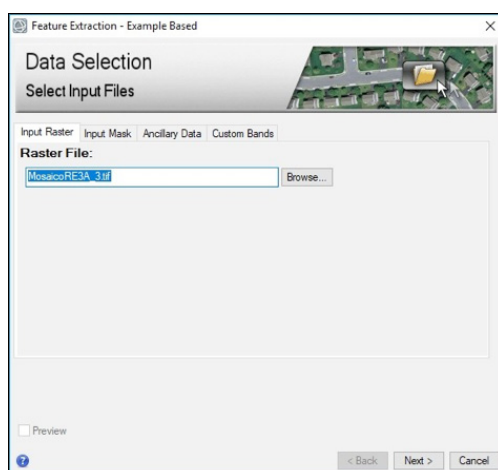


Figura 61. Data Selection – Select Input Files – Input Raster

Input Mask or Ancillary Data: En este visor se puede subir información vector o raster que sirvan como máscaras o información auxiliar para la clasificación. En este caso no se han empleado máscaras o información auxiliar. Sin embargo, en caso de tenerlas, recuerde activar el cuadro de Inverse Mask si la máscara es por fuera del área de trabajo (Figura 62):

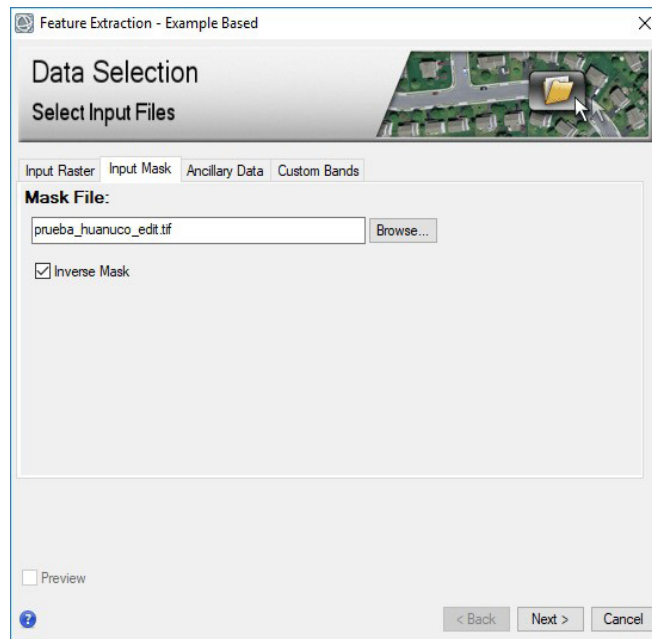


Figura 62. Data Selection – Select Input Files – Input Mask (Ancillary Data)

Custom Bands: En este visor se puede calcular el índice normalizado de vegetación (NDVI) u otros índices para que sirvan como insumos a la segmentación y clasificación. Para adicionar el NDVI en el proceso active la opción Normalized Difference → Banda 1 seleccionar Banda 3 y en Banda 2 Seleccionar Banda 5 (Figura 63) → Clic Next.

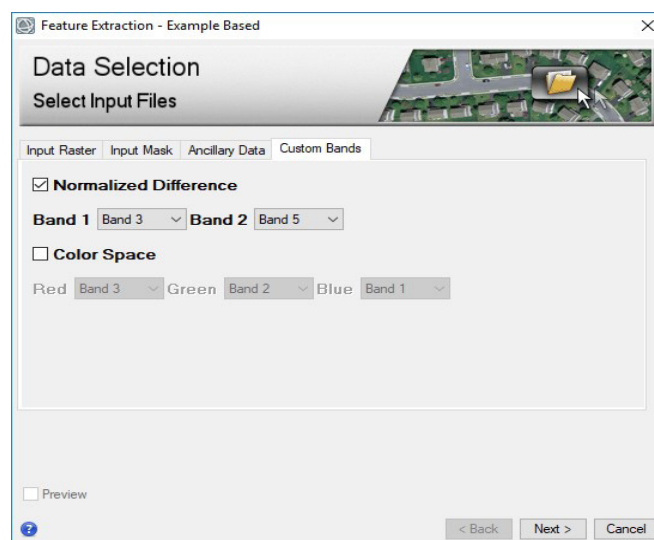


Figura 63. Data Selection – Select Input Files – Custom Bands

## 2. SEGMENTACIÓN DE LA IMAGEN

El proceso de segmentación divide la imagen en agrupaciones de píxeles vecinos con valores espectrales, espaciales y/o texturales similares, unidos por un vector de área denominado segmento. Los segmentos generados por medio de este proceso pueden definirse como objetos de imágenes o pseudo-polígonos. Los valores asignados a las variables de tamaño y forma son los que permiten que los segmentos se ajusten a las características espaciales de las coberturas que se desean clasificar y a la escala de análisis, como el área mínima de una parcela, por ejemplo. El conjunto de variables cambia de acuerdo al algoritmo empleado; sin embargo, en general, todos los algoritmos permiten manipular el tamaño de los segmentos, su forma y el grado de compactación. Una segmentación efectiva garantiza que los resultados de su clasificación se ajusten bien a las características espaciales vistas en las imágenes. En este paso se debe seleccionar los mejores parámetros de segmentación para cada mosaico (departamento). Para cada departamento se realizan pruebas variando los siguientes parámetros, como se muestra en la Figura 64:

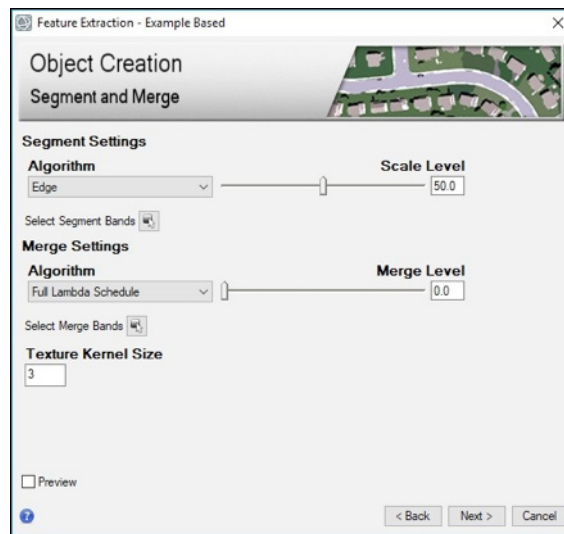


Figura 64. Parámetros de segmentación

### 2.1. CONFIGURACIÓN DE LA SEGMENTACIÓN (SEGMENTATION SETTINGS)

Seleccione un algoritmo de segmentación de la lista desplegable. Las opciones disponibles son: Edge (separa objetos con bordes definidos) e Intensity (promedia los valores del píxel entre bandas y usa este valor promedio para segmentar).

Seleccione el nivel de escala de la segmentación: Scale Level (el nivel de escala o nivel de segmentación va de 0 a 100, siendo el cercano a 0 la segmentación fina y 100 la segmentación gruesa). (Figura 65).

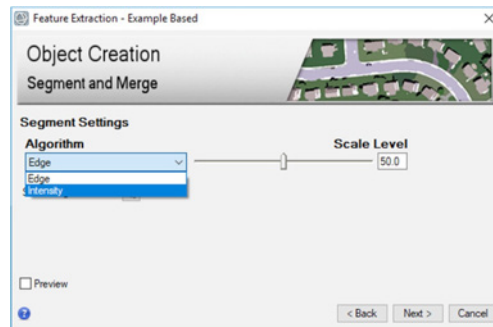


Figura 65. Ajustes de segmentación

## 2.2. CONFIGURACIÓN DE LA INTEGRACIÓN DE SEGMENTOS (MERGE SETTINGS)

Seleccione un algoritmo de unión de la lista desplegable. Las opciones disponibles son: Full Lambda Schedule (une pequeños segmentos dentro de un área texturizada mayor) y Fast Lambda (une segmentos adyacentes con colores y tamaños de borde similares). Seleccione el nivel de escala de unión: Merge Level (el nivel de unión va de 0 a 100). Valores altos de este parámetro produce imágenes menos segmentadas, mientras que valores de 0 resulta en una mayor segmentación, se recomienda usar el nivel más alto de unión que permita definir los límites de las figuras. (Figura 66).

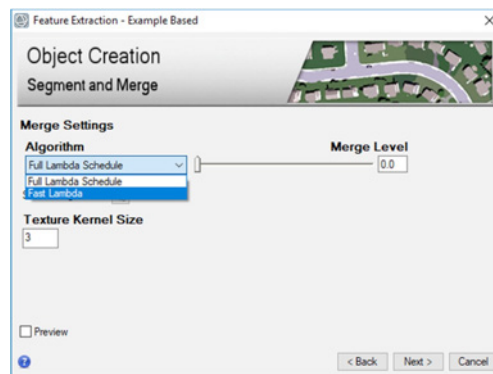


Figura 66. Ajustes de Merge

## 2.3. CONFIGURACIÓN DEL CLASIFICADOR POR TEXTURA (TEXTURE KERNEL SIZE)

Este valor indica el tamaño de la ventana en la cual se medirán los atributos de textura. Esta va desde un valor de 3 (ventana de 3x3 píxeles) al valor máximo de 19 (ventana de 19x19 píxeles).

Juegue con estos parámetros hasta obtener una segmentación adecuada, recuerde que demasiados segmentos incrementan significativamente el tiempo de procesamiento. Se recomienda utilizar el algoritmo de segmentación Edge, debido a que este algoritmo utiliza como base el valor de los colores de los píxeles, los cuales deben ponerse a variar entre valores de 30 y 50, de acuerdo a los segmentos que quieras separar.

También, se recomienda usar el algoritmo Full Lambda Schedule, con valores de nivel de Merge entre 70 y 80 que permitan una segmentación apropiada no muy fina. Finalmente, utilice una ventana de Kernel de tamaño entre 5 y 9 píxeles, dependiendo de las diferencias texturales entre coberturas que se desean clasificar. Este proceso tiene una duración variable de acuerdo al tamaño de la imagen o la velocidad de procesamiento de su equipo.

En promedio, un mosaico de 50Gb puede tardar ocho horas en ser procesado. De una buena segmentación se deriva una buena clasificación, por lo que una inspección visual es completamente necesaria; de esta manera, se puede verificar que las áreas que se desean clasificar hayan sido separadas en segmentos independientes. Una vez obtenida una segmentación satisfactoria se procede a la clasificación.

### 3. CLASIFICACIÓN DE LA IMAGEN SEGMENTADA

#### 3.1. SELECCIÓN DE LAS SEMILLAS O ÁREAS DE ENTRENAMIENTO

Una vez producida la segmentación, el sistema despliega una nueva ventana con los primeros pasos necesarios para elaborar la clasificación (Figura 67). Esta ventana contiene tres pestañas: Example selection, Attributes selection y Algorithms.

La primera pestaña Examples selection permite hacer la selección de las áreas de entrenamiento por cobertura. La carpeta llamada All Classes contiene las clases o nombre de las coberturas que serán clasificadas, estas clases son creadas, nombradas y personalizadas por el usuario (pastos, bosques, agua, etc.). Para agregar una clase nueva se debe dar click en el símbolo más (+), después se puede editar el nombre y asignar un color de preferencia, como se muestra en la Figura 68:

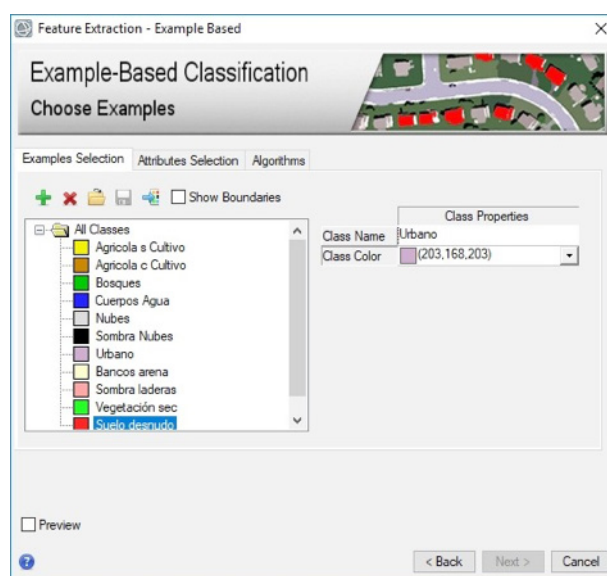


Figura 67. Ventana de clasificación o de elección de semillas




Figura 68. Imagen segmentada

Al mover el cursor, por la imagen segmentada, se resalta en azul magenta el segmento sobre el cual se encuentra el cursor, de esta manera es fácil identificar los segmentos que serán seleccionados como áreas de entrenamiento. Para seleccionar los segmentos que van a formar parte o representan a criterio del experto una misma clase, se debe dar click sobre el segmento seleccionado. El color del segmento cambia (Figura 69) y la clase se actualiza con el número de semillas que son agregadas. Use el botón más verde (+) para adicionar más clases.


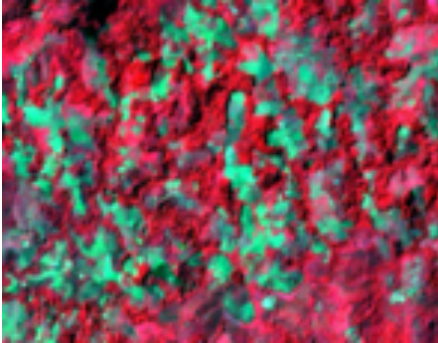
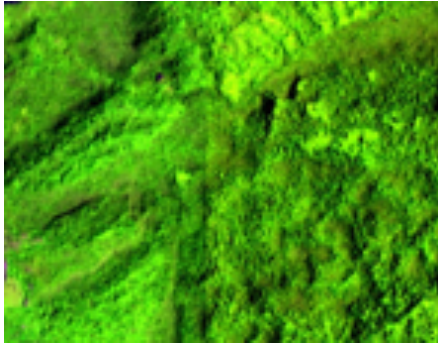
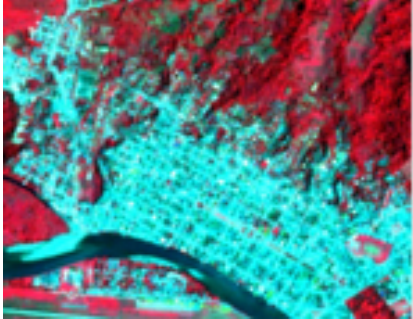
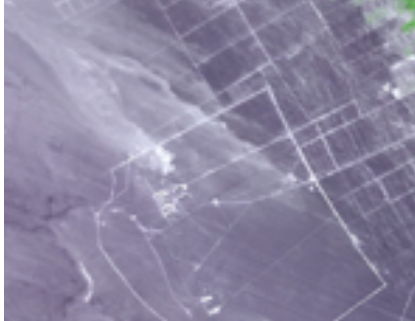
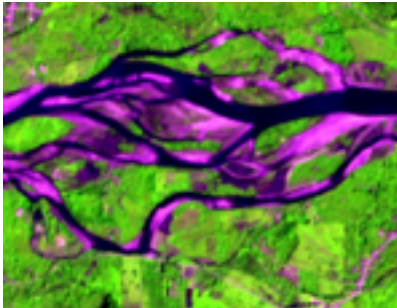
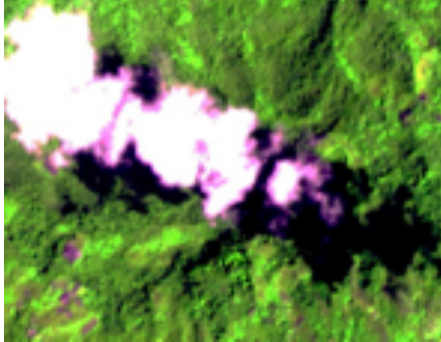


Figura 69. Imagen segmentada

Se recomienda seleccionar segmentos con diferentes texturas, tonos y tamaños para que el grupo de áreas de entrenamiento cubra toda la variabilidad de cada clase. Las clases que se deben definir para la metodología de Perú las podemos ver en la Tabla 8:



Tabla 8. Coberturas a clasificar

Cobertura agrícola	Cobertura de Bosque
	
Zona urbana e infraestructura	Suelos Eriazos
	
Cuerpos de agua	Coberturas de nubes y sombras
	

### 3.2. ANÁLISIS DE SEPARABILIDAD DE LAS ÁREAS DE ENTRENAMIENTO

El análisis de separabilidad indica que tan consistentes estadísticamente son las áreas de entrenamiento seleccionadas, es decir, si son lo suficientemente independientes y diferenciables entre sí las diferentes coberturas que queremos clasificar.

Los valores de “separabilidad” oscilan entre 0 y 2, cuando estos son superiores a 1.9 indica una alta separabilidad, lo que significa que son distintos. Para las áreas de entrenamiento menores a 1.6, es necesario editar o seleccionar nuevas áreas para obtener mayores valores de separabilidad. El análisis de separabilidad se realiza de la siguiente manera:

Desde el ENVI 5.1, seguido de la carga de la imagen y las semillas en formato shapefile File → Open, Ambas se despliegan en la ventana Data Manager, abrir la ventana de Roi e importar el vector, como se ve en la siguiente ventana (Figura 70):

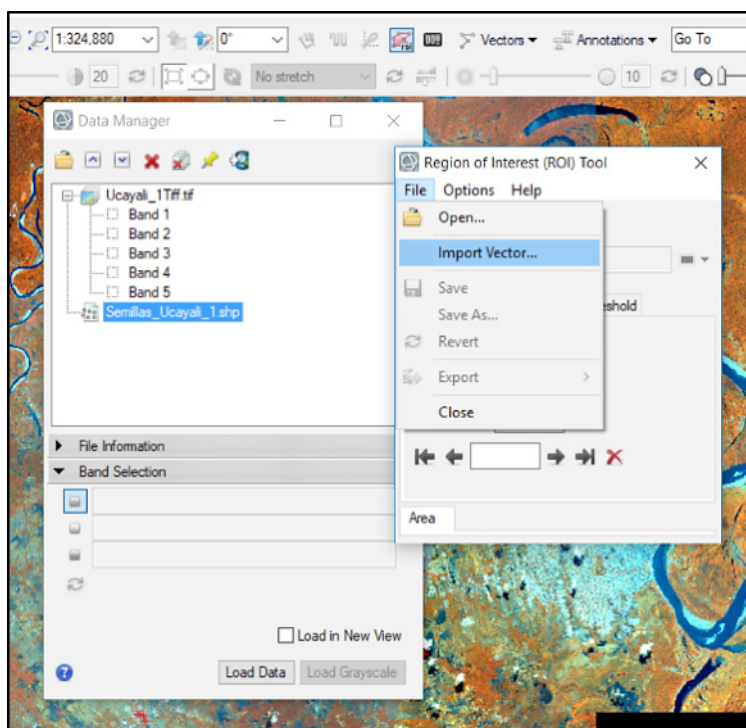


Figura 70. Ventana para cargar las áreas de entrenamiento

Seleccionar el shapefile, en la ventana Convert Vector to ROIs Hacer click → Unique records of an attribute to separate ROIs, seleccionar la columna Class\_Name y dar Ok. (Figura 71).

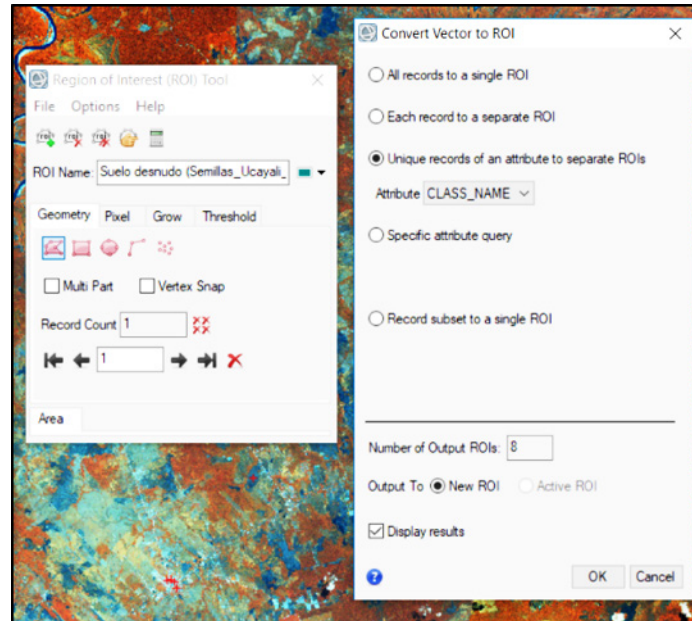


Figura 71. Forma de cargar las semillas en la herramienta ROI en ENVI

Desde la ventana Roi Tool ir a Options y seleccionar Compute ROI separability, y seleccionar la imagen y las semillas y OK (Figura 72).

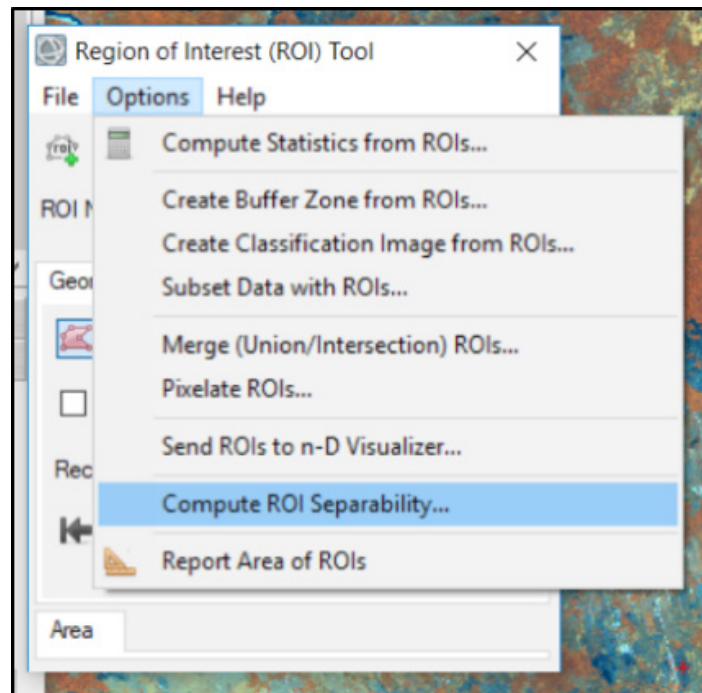


Figura 72. Ruta para acceder a la herramienta de cómputo de separabilidad de áreas de entrenamiento

El resultado del cómputo de separabilidad se despliega en un archivo de texto con la información de la separabilidad por cada clase, como se muestra en la Figura 73.

```
(Class_F=Tierras Agrícolas) [White] 239 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Otros usos) [White] 117 points - 1.00540935
(Class_F=Tierras Agrícolas) [White] 239 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Bosques) [White] 27 points - 1.46526790
(Class_F=Otros usos) [White] 117 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Nubes) [White] 58 points - 1.66503682
(Class_F=Otros usos) [White] 117 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Cuerpos de agua) [White] 42 points - 1.80681730
(Class_F=Tierras Agrícolas) [White] 239 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Nubes) [White] 58 points - 1.81290318
(Class_F=Bosques) [White] 27 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Sombras de nubes) [White] 35 points - 1.86674922
(Class_F=Otros usos) [White] 117 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Bosques) [White] 27 points - 1.88694464
(Class_F=Otros usos) [White] 117 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Sombras de nubes) [White] 35 points - 1.89752448
(Class_F=Tierras Agrícolas) [White] 239 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Cuerpos de agua) [White] 42 points - 1.91578307
(Class_F=Bosques) [White] 27 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Nubes) [White] 58 points - 1.95100657
(Class_F=Tierras Agrícolas) [White] 239 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Sombras de nubes) [White] 35 points - 1.96066311
(Class_F=Cuerpos de agua) [White] 42 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Nubes) [White] 58 points - 1.97307825
(Class_F=Nubes) [White] 58 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Sombras de nubes) [White] 35 points - 1.98369200
(Class_F=Cuerpos de agua) [White] 42 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Sombras de nubes) [White] 35 points - 1.98874989
(Class_F=Bosques) [White] 27 points and EVF: Layer: Semillas_CajamarcaDissolve.shp (Class_F=Cuerpos de agua) [White] 42 points - 1.99919213
```

Figura 73. Ejemplo de reporte de análisis de separabilidad de áreas de entrenamiento

### 3.3. SELECCIÓN DE LOS PARÁMETROS DE CLASIFICACIÓN

Una vez realizada la selección de las semillas por cada clase o cobertura, se procede a activar la segunda pestaña Attributes Selection. En esta ventana se escogen los atributos que serán considerados en la clasificación. Es decir, el software computa estas estadísticas para las semillas y las usa como valores de referencia para cada clase, con el fin de asignar a los demás segmentos las diferentes clases. Los atributos pueden ser de tres tipos: espectrales, texturales y espaciales. Para seleccionar un atributo, seleccione el nombre y dé clic en el botón →, y para removerlo da clic en el botón ←. Al seleccionar un atributo espectral o de textura el software por defecto realizará los cálculos para todas las bandas de la imagen, pero también se puede definir cuáles bandas específicamente se desean tener en cuenta, omitir o darle un tratamiento diferenciado en relación a la demás bandas(Figura 74).

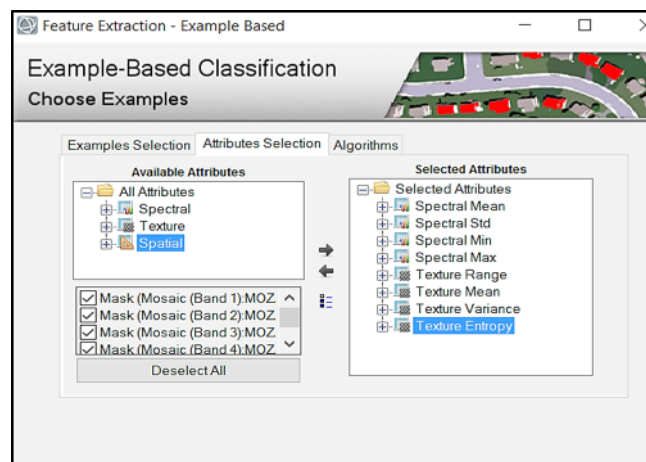


Figura 74. Selección de atributos

Finalmente, el algoritmo de clasificación es seleccionado en la tercera pestaña Algorithms. Se puede elegir entre tres algoritmos: el primero es el del vecino más cercano, (KNN, por sus siglas en inglés). Este método clasifica los segmentos basados en la proximidad de las semillas de entrenamiento vecinas, es el método más preciso para distinguir entre clases similares, sólo es necesario definir una clase para correr el proceso. El segundo, es el de análisis de componentes principales (PCA, por sus siglas en inglés). Este método asigna segmentos a clases usando análisis de componentes principales, en este método se debe de definir, al menos, dos clases con un mínimo de dos semillas en cada una. El tercero es la máquina de vectores soporte (SVM, por sus siglas en inglés). Este es el método más riguroso, cada clase debe tener como mínimo dos semillas de lo contrario será excluida de la clasificación. Este algoritmo es utilizado en la clasificación de las coberturas.

Adicionalmente, se debe deshabilitar la opción sin clasificación “Allow Unclassified” la cual permite que algunos segmentos se puedan quedar sin una clase asignada cuando el clasificador no puede determinar a qué clase pertenece. Los demás valores pueden dejarse por defecto (Figura 75):

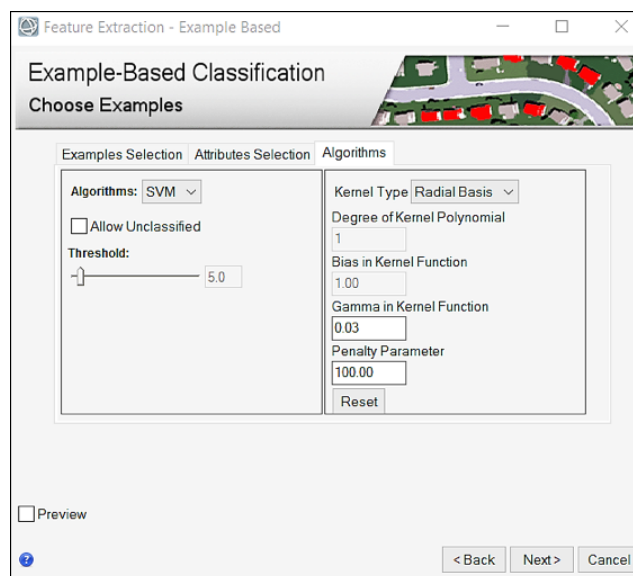


Figura 75. Selección de algoritmos

Al igual que en la segmentación, ENVI requiere de mucho tiempo para procesar la clasificación. En promedio puede tardar ocho horas para archivos de un área de “x” por “y” píxeles.

### 3.4. EXPORTAR LOS ARCHIVOS DE CLASIFICACIÓN

Una vez obtenida la clasificación, el flujo de trabajo muestra una última ventana con los parámetros que permiten exportar y guardar los resultados. En esta ventana se debe deshabilitar la opción Merge Adjacent Features, para evitar que los segmentos sean unidos por las clases a clasificar. Finalmente, la capa clasificada se exporta en formato shape o en GDB, como se muestra en la Figura 76.

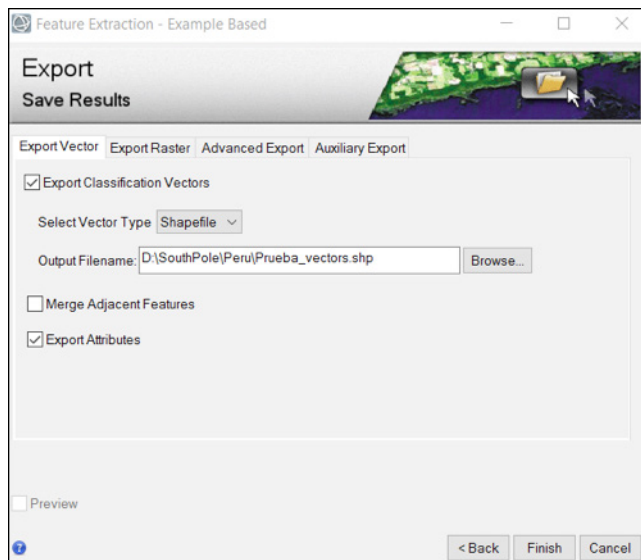


Figura 76. Guardado de clasificación en formato shape o GDB

Al obtener la clasificación de las coberturas se procede a la post clasificación de la información vectorial.

#### 4. PROCESAMIENTO POST CLASIFICACIÓN

Después de evaluar el resultado de la clasificación, se procede a realizar la limpieza y filtrado de los vectores que conforman la clasificación. Para este post procesamiento se utiliza la función de ArcGis Data Management tools → Generalization → Eliminate. Esta función permite eliminar los polígonos menores a 0,5 hectáreas fusionándolos al vecino más cercano. Posteriormente, se abre la capa en ArcGIS y se procede a revisar y categorizar adecuadamente las clases de las coberturas a una escala 1:10.000 con el objetivo de corregir errores mayores en la clasificación. Los errores mayores hacen referencia a agrupaciones de polígonos clasificados erróneamente; por ejemplo, cuando las sombras de nubes son clasificadas como agua, o bosques como sombras de nubes, etc. En los casos en los que se encuentran errores de clasificación sistemáticos, se realiza la reasignación manual de la cobertura correcta.

#### 5. CÁLCULO DEL ERROR DE CLASIFICACIÓN

Para el cálculo del error de clasificación se requieren dos insumos: una fuente de información estimada (la clasificación) y otra real (muestra de segmentos de control). La información estimada se compara con la real, permitiendo conocer el índice de Exactitud Global y el índice Kappa, en función de los errores de omisión y comisión. El cálculo del error se realiza con el programa ArcGIS, dividido en un flujo de trabajo de tres fases: 1) el cálculo del tamaño de la muestra de segmentos de control, 2) la extracción de dicha muestra, y 3) el cálculo de error de clasificación.

## 5.1. CÁLCULO DEL TAMAÑO DE LA MUESTRA DE SEGMENTOS DE CONTROL

Debido a que los archivos de vectores, producto de la clasificación de cada departamento, contiene un número de polígono diferente para cada cobertura clasificada, es necesario calcular el tamaño de la muestra adecuado que constituirá la fuente de información real. El tamaño de la muestra se calcula utilizando una prueba Z dado un tamaño de la población finita (número total de segmentos de la clasificación), con un margen de error del 5% y un nivel de confianza del 95%, como se muestra en la siguiente función:

$$n = \frac{(Z^2 * p * q * N)}{(N * e^2 + Z^2 * p * q)}$$

Donde:

Z = nivel de confianza (valor 1.96 a un 95% de confianza)

p = Probabilidad a favor.

q = Probabilidad en contra.

N = Universo

e = error de estimación.

n = tamaño de la muestra

Por ejemplo, para una población de 296,955 segmentos con un margen de error máximo esperado del 5%, el tamaño de muestra para un nivel de confianza del 95% es de 384 segmentos.

## 5.2. OBTENCIÓN DE LA MUESTRA DE SEGMENTOS DE CONTROL

Una vez calculado el tamaño de la muestra de segmentos de control se procede a seleccionar los puntos de control de forma aleatoria en toda la extensión de la clasificación y de forma estratificada por las clases del nivel 2 (el número de puntos asociado a cada clase se pondera por el porcentaje de área que representa con respecto al número de puntos totales).

A continuación, se detalla el proceso en ArcGIS: Abrir ArcMap y desplegar el producto final de la clasificación. Luego se rasteriza el archivo vectorial utilizando la herramienta Feature to Raster ubicado en Toolboxes → System Toolboxes → Conversion Tools.tbx → To Raster → Feature to Raster. Al final, se procede a llenar los campos. Primero, seleccionando la clasificación (archivo vectorial) en Input Features, luego escoger el campo Nivel\_2, establecer la ruta donde se desea guardar el producto de salida y se culmina escogiendo la resolución espacial del raster, que para imágenes RapidEye es de 5 m (debe ser la misma resolución de la imagen multiespectral donde procede la clasificación) (Figura 77).

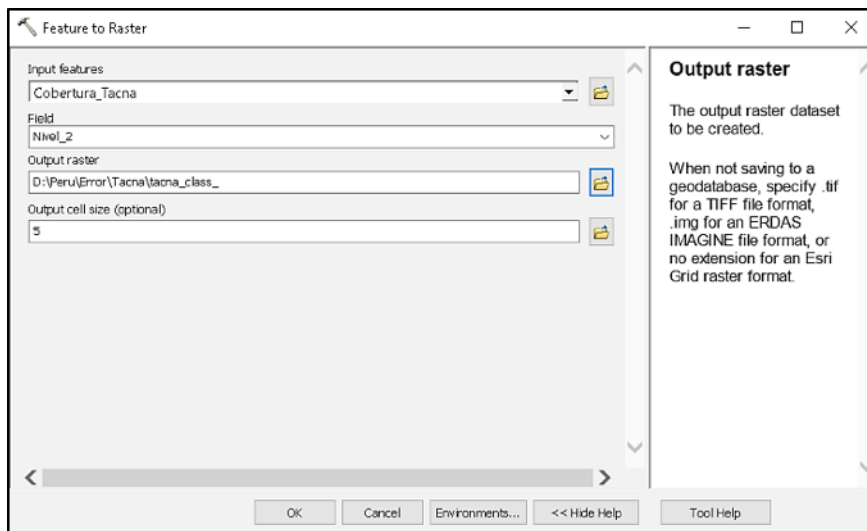


Figura 77. Opciones de la herramienta Feature to Raster del ArcMap

El producto de salida de esta herramienta es un raster, donde la categoría corresponde a las clases del nivel 2 de Corine Land cover (Figura 78).

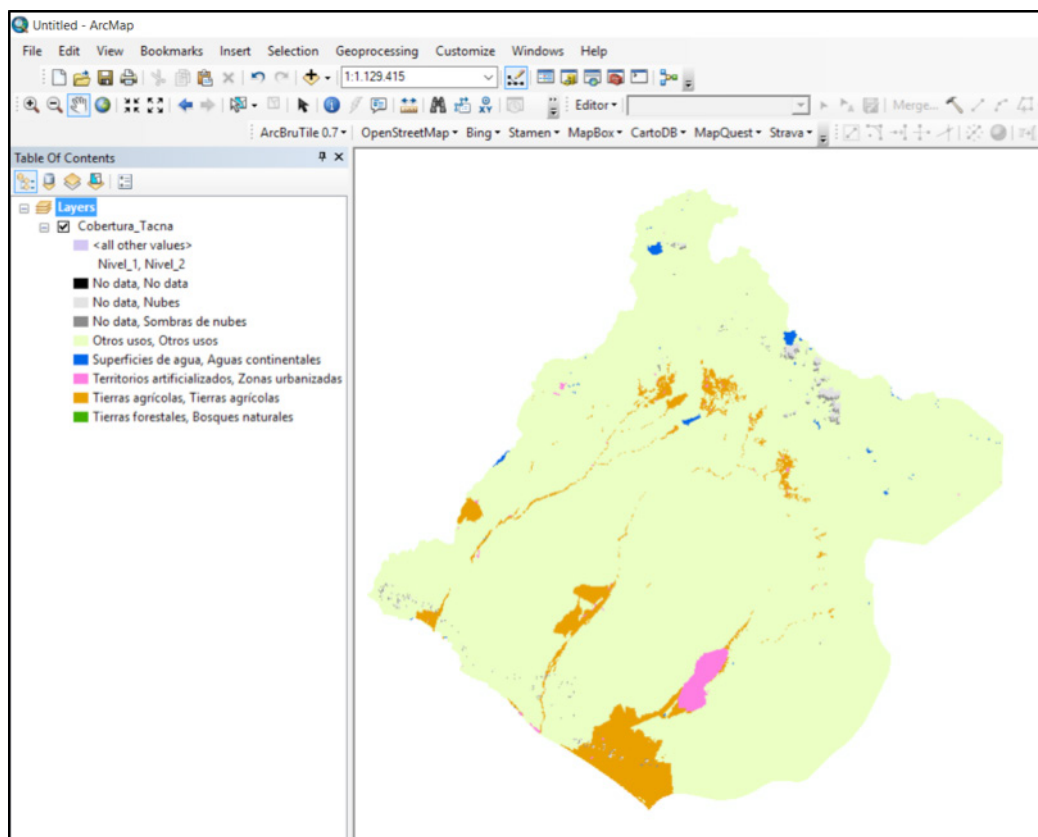


Figura 78. Raster de la clasificación final



Ahora, se procede a generar el producto vectorial que contiene los puntos de control utilizando la herramienta Create Accuracy Assessment Points, ubicada en la siguiente ruta: Toolboxes → System → Toolboxes → Spatial Analyst Tools.tbx → Segmentation and Classification → Create Accuracy Assessment Points.

Primero, cargar el archivo raster de la clasificación y establecer la ruta donde se desea guardar los puntos de control (se debe guardar el producto dentro de una geodatabase). Luego, escoger el Target CLASSIFIED porque el raster de entrada es la clasificación. Luego, escribir el tamaño basado en el cálculo realizado en el apartado anterior. La estrategia de muestreo es STRATIFIED\_RANDOM, donde el número de puntos por clase dependen del porcentaje de área que representa cada una con respecto al total (selección por ponderación) y el mínimo de puntos por clase son 10 (Figura 79).

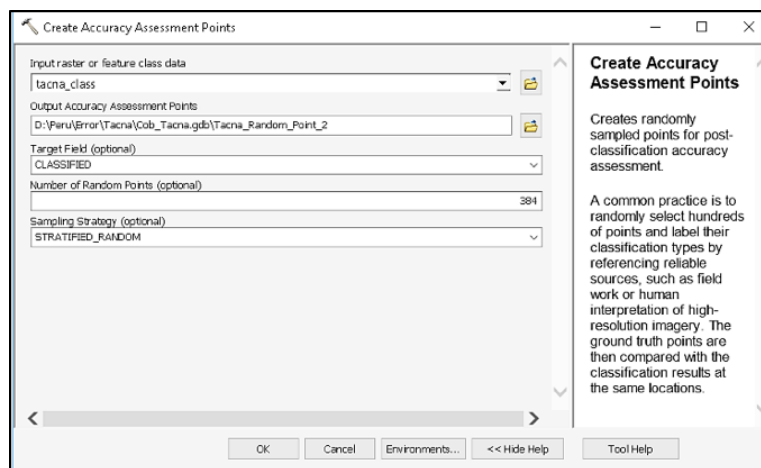


Figura 79. Herramienta “Create Accuracy Assessment Points”

El resultado final es un archivo vectorial con los puntos de control a calificar (Figura 80)

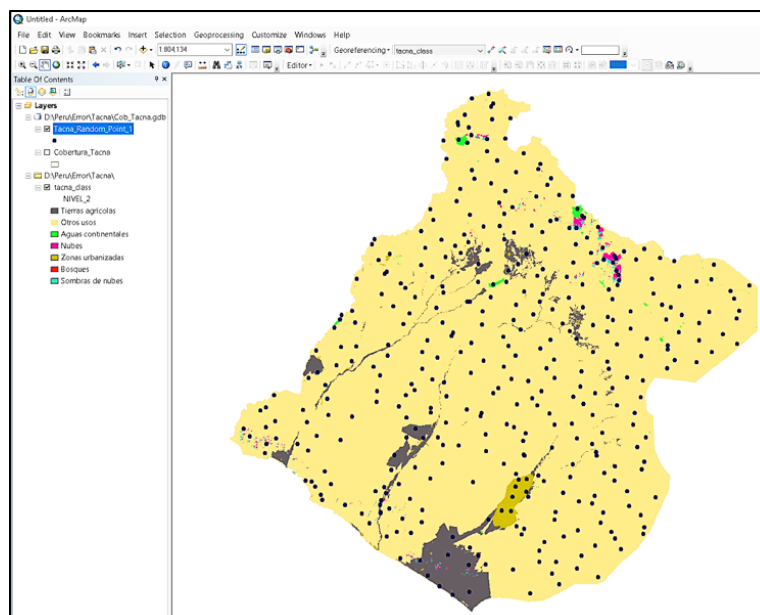


Figura 80. Resultado de la creación de puntos de control

La evaluación de los puntos de control se hace sobre segmentos (polígonos), para que el intérprete externo haga su juicio de cada una de las clases bajo las mismas condiciones del flujo de trabajo que se hace en la post clasificación. Para realizar esa labor en ArcGIS, ir a la barra de herramientas de ArcMap y dar click en Selection → Selection by Location, en Target Layer seleccionar el archivo vectorial de la clasificación final.

En Source layer, seleccionar la capa de puntos aleatorios, click en aplicar (Figura 81).

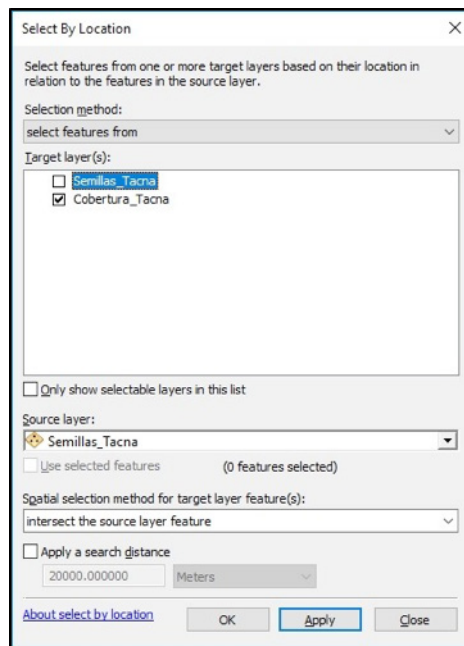


Figura 81. Herramienta para la selección de polígonos que coinciden con los puntos de control

Como resultado se visualizan, resaltados en color cian, los segmentos que se interceptan con los puntos y que serán extraídos para su interpretación (Figura 82).

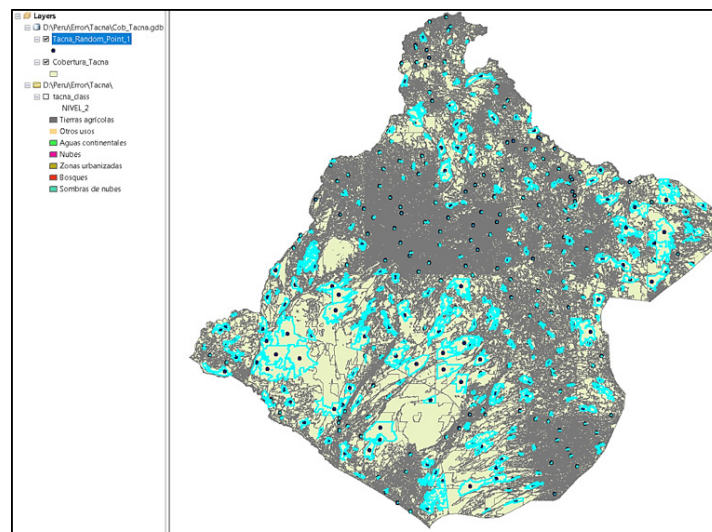


Figura 82. Polígonos coincidentes con los puntos de control

Para exportar los polígonos se debe de ir a la tabla de contenido, posicionar el cursor sobre la capa de coberturas, dar click derecho, y se despliega una ventana donde se le da click a la opción Data → Export Data y el usuario, al final, establece la ruta donde desea que se grabe el archivo (Figura 83).

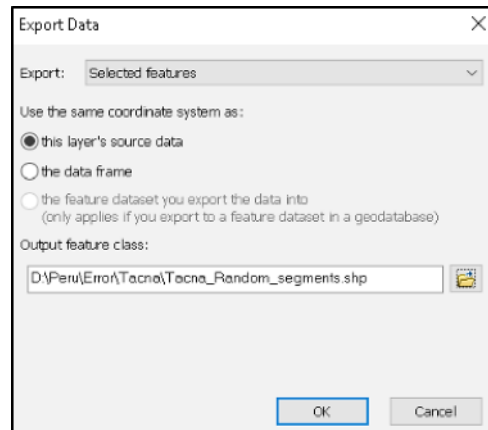


Figura 83. Herramienta para exportar los polígonos coincidentes con los puntos de control

Como resultado, los segmentos elegidos aleatoriamente como áreas de control se cargan sobre el mosaico del departamento para iniciar las actividades de inspección visual (Figura 84).

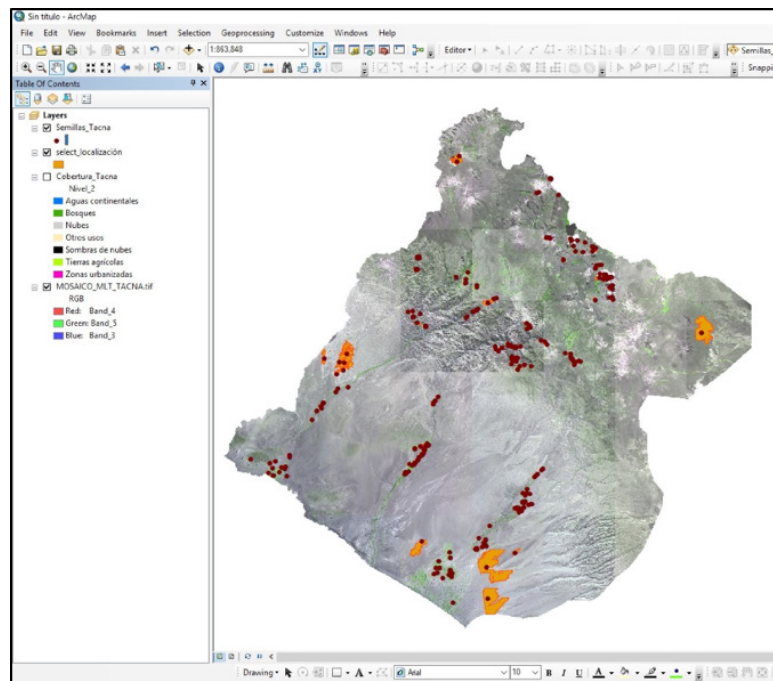


Figura 84. Set de polígonos de control

Al archivo vectorial, con los segmentos a evaluar, se le crea una nueva columna en la tabla de atributos con nombre Predict, tipo Long Integer y precisión 0, para que el intérprete consigne su evaluación (Figura 85).

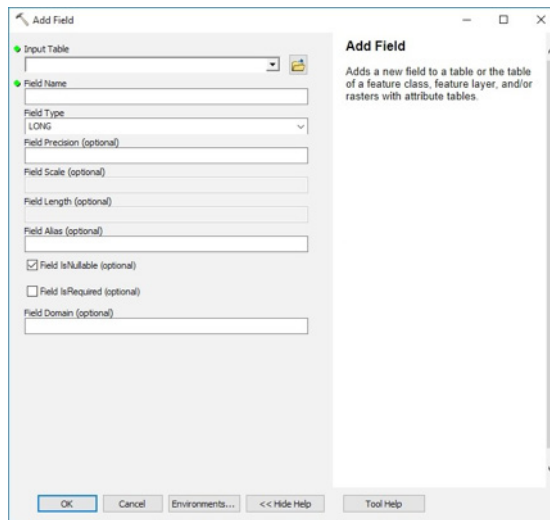


Figura 85. Herramienta para crear columnas en la tabla de atributos

La inspección visual se hace por cada polígono y el intérprete debe colocar en la nueva columna Predict un valor de 1 a 7, que hace referencia a la asignación de cada una de las clases de la rasterización. Para ver qué valor tiene cada clase, abrir la tabla de atributos del raster y correlacionar la columna Value con su respectivo nombre de la cobertura del NIVEL\_2 del método CORINE land cover. Al final, el intérprete debe llenar la columna Predict (Figura 86).

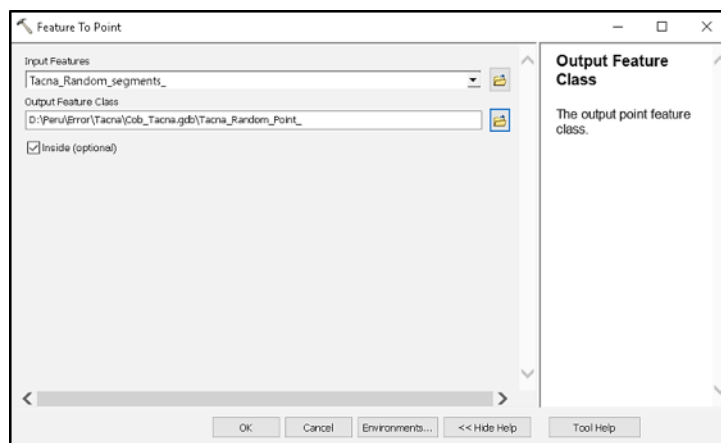
	Nivel_2	Eriazos	Shape_Leng	Shape_Area	Predict
	Zonas urbanizadas	No	10910	508525	5
	Zonas urbanizadas	No	7440.221625	466132.83446	5
	Zonas urbanizadas	No	420	4575	5
	Zonas urbanizadas	No	1020	25700	1
	Otros usos	No	86880	29327425	2
	Otros usos	No	11240	1723000	2
	Zonas urbanizadas	No	10698.03245	778437.958652	2
	Zonas urbanizadas	No	23984.12853	2183928.32095	5
	Otros usos	No	47880	11035975	2
	Otros usos	No	25610	6073875	2
	Otros usos	No	13080	1181675	2
	Otros usos	No	19440	1529750	2
	Otros usos	No	70040	20334200	2
	Aguas continentales	No	14460	3686875	3
	Otros usos	No	3060	89700	2
	Otros usos	No	10770	865500.000001	2
	Otros usos	No	40820	5810150	2
	Otros usos	No	30200	3677975	2
	Otros usos	No	28320	4708350	2
	Otros usos	No	11550	751874.999998	2

Figura 86. Tabla de atributos de la muestra de segmentos de control con la columna Predict diligenciada

### 5.3. CÁLCULO DEL ERROR

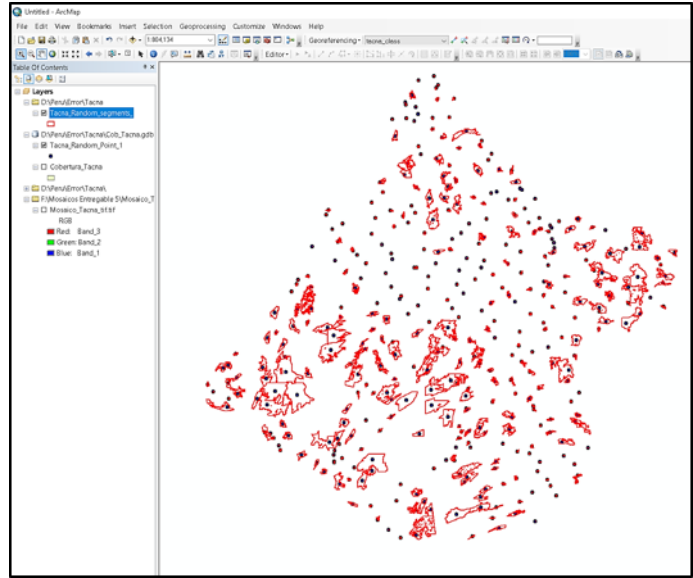
El cálculo del error se concentra en cuantificar Índice de Exactitud Global y el Índice de Kappa utilizando el método de la matriz de confusión en función de los errores de omisión y comisión. Los cálculos en ArcMap se hace utilizando el toolbox Compute Confusion Matrix ubicado en la siguiente ruta: Toolboxes → System Toolboxes → Spatial Analyst Tools.tbx → Segmentation and Classification → Compute Confusion Matrix, pero para ejecutar esta opción es necesario darle un tratamiento especial a los archivos de entrada:

Primero, los archivos vectoriales con los segmentos de control se deben convertir a puntos de control. En ArcGIS utilizar el toolbox Feature to Point en la siguiente ruta: Toolboxes → System Toolboxes → Data Management Tools.tbx → Features → Feature to Point. La entrada es el vector con los polígonos de control, luego se establece la ruta de salida, donde deseamos que quede guardado nuestro archivo de puntos y se termina activando la casilla Inside, para garantizar que cada punto quede dentro de cada polígono (Figura 87).



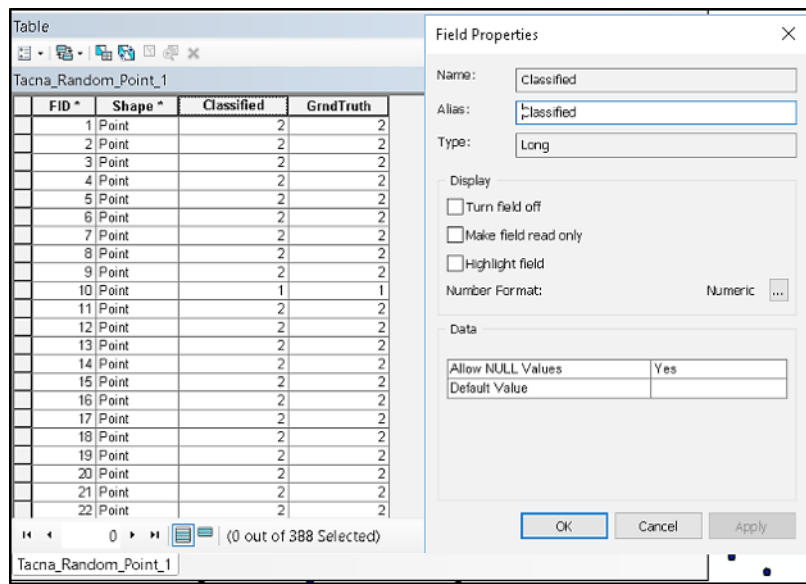
**Figura 87.** Conversión de polígonos a puntos de los segmentos de control

El resultado lo podemos apreciar en la Figura 88:



**Figura 88.** Resultado de la conversión de polígonos a puntos de los segmentos de control

Segundo, al vector con los puntos de control hay que crearle dos nuevas columnas en la tabla de atributos con nombres precisos. Las columnas se llaman Classified y GrndTruth, tipo Long Integer y precisión (Figura 89).



**Figura 89.** Creación de nuevas columnas al vector con puntos de control

Tercero, llenar las columnas Classified y GrndTruth. Para calcular Classified se llena teniendo como referencia la columna NIVEL\_2 y los valores asignados en la rasterización de la clasificación, y para la columna GrndTruth se calcula con los mismos valores de la columna Predict (Figuras 90 y 91).

Rowid	VALUE	COUNT	NIVEL_2
0	1	33042737	Tierras agrícolas
1	2	598013457	Otros usos
2	3	1636996	Aguas continentales
3	4	2392161	Nubes
4	5	5341168	Zonas urbanizadas
5	6	21208	Bosques
6	7	1657938	Sombras de nubes

Figura 90. Tabla de atributos de la clasificación (segmentación) para el cálculo del error

Nivel_2	Erizos	Shape_Leng	Shape_Area	Predict	Classified	GrndTruth
Otros usos	No	2100	39999.999999	2	0	0
Otros usos	No	16150	970700	2	0	0
Otros usos	No	3490	60235	2	0	0
Otros usos	No	37610	4482100	2	0	0
Otros usos	Si	14700	902075	2	0	0
Otros usos	Si	17400	1533125	2	0	0
Otros usos	Si	34390	6791925	2	0	0
Otros usos	Si	97660	18166975	2	0	0
Otros usos	No	31750	4718100	2	0	0
Tierras agrícolas	No	10623.917046	891687.260126	1	0	0
Otros usos	Si	29060	5096025	2	0	0
Otros usos	No	18620	1778150	2	0	0
Otros usos	Si	78870	28181000	2	0	0
Otros usos	Si	21340	2172275	2	0	0
Otros usos	Si	27962.917668	5684023.89018	2	0	0
Otros usos	Si	33210	2862750	2	0	0
Otros usos	Si	14110	99824.999999	2	0	0
Otros usos	Si	49000	2275625	2	0	0
Otros usos	No	88840	18024075	2	0	0
Otros usos	Si	13080	93300	2	0	0
Otros usos	Si	35220	5027575	2	0	0

Figura 91. Tabla de atributos de la muestra (valor estimado)

Cuarto, hay que eliminar todas las columnas del archivo de puntos, excepto Classified y GrndTruth. En ArcGIS abrir el toolbox Delete Field en la siguiente ruta Toolboxes → System Toolboxes → Data Management Tools.tbx → Fields → Delete Field (Figura 92).

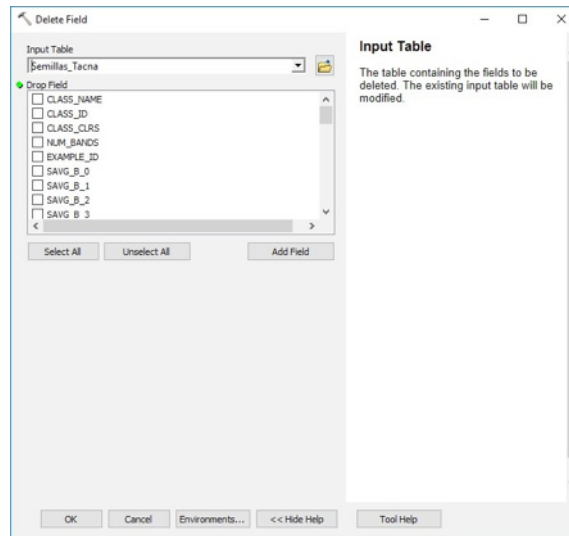


Figura 92. Borrado de campos del resultado del cálculo del error

Resultado final de borrar los campos (Figura 93).

FID *	Shape *	Classified	GrndTruth
1	Point	2	2
2	Point	2	2
3	Point	2	2
4	Point	2	2
5	Point	2	2
6	Point	2	2
7	Point	2	2
8	Point	2	2
9	Point	2	2
10	Point	1	1
11	Point	2	2
12	Point	2	2
13	Point	2	2
14	Point	2	2
15	Point	2	2
16	Point	2	2
17	Point	2	2
18	Point	2	2
19	Point	2	2
20	Point	2	2
21	Point	2	2
22	Point	2	2

Figura 93. Resultado final del borrado de campos del cálculo del error

Después de haber organizado la información de entrada, abrir el toolbox Compute Confusion Matrix, seleccionar los puntos de control y guardar la tabla fuera de una geodatabase con formato .dbf (Figura 94)



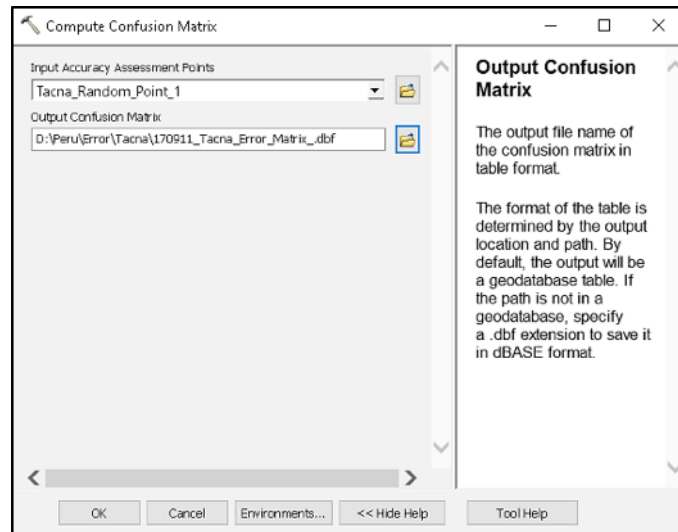


Figura 94. Ventana del Compute Confusion Matrix

Como resultado final se obtiene la matriz de confusión. Se posiciona el cursor sobre el archivo generado en la tabla de contenido, se da click derecho y se selecciona la opción abrir. Se despliega una ventana con el valor del Índice de Exactitud Global, como se ve en la imagen inferior resaltado con color azul y el Índice de Kappa resaltado de color rojo (Figura 95).

OID	ClassValue	C_1	C_2	C_3	C_4	C_5	C_6	C_7	Total	U Accuracy	Kappa
0	C_1	15	4	0	0	0	1	0	20	0.75	0
1	C_2	6	321	0	0	0	0	0	327	0.981651	0
2	C_3	0	2	6	0	0	0	0	8	0.75	0
3	C_4	0	2	0	8	0	0	0	10	0.8	0
4	C_5	1	1	0	0	6	0	0	8	0.75	0
5	C_6	0	0	0	0	0	5	0	5	1	0
6	C_7	0	1	0	1	0	0	8	10	0.8	0
7	Total	22	331	6	9	6	6	8	388	0	0
8	P_Accuracy	0.681818	0.969789	1	0.888889	1	0.833333	1	0	0.951031	0
9	Kappa	0	0	0	0	0	0	0	0	0.822665	0

Figura 95. Matriz de confusión

## Referencias

- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 2-16.
- Cicero. (45 BC). *de Finibus Bonorum et Malorum*.
- Exelis Visual Information Solutions. (2010). *Feature extraction Module version 4.6*. CO, USA: Exelis Visual Information Solutions.
- Qin, Y., Niu, Z., Chen, F., Li, B., & Ban, Y. (2013). Object-based land cover change detection for cross-sensor images. *International Journal of Remote Sensing*, 34, 6723-6737.

## X. Complemento metodológico de clasificación de cobertura

Este módulo permite una introducción a las principales características y funciones necesarias para un desenvolvimiento oportuno en el software. El usuario podrá abrir y administrar datos satelitales, generar distintos segmentos, realizar una clasificación y exportar resultados.

Cabe hacer mención que el software eCognition posee cuatro versiones:

- eCognition Developer: Es el módulo que permite combinar los algoritmos existentes y definir las estrategias que se aplicarán sobre los datos geográficos utilizados.
- eCognition Architect: La estrategia diseñada en eCognition Developer puede resultar muy complicada de utilizar para alguien que no sea experto o conocedor de eCognition. El módulo Architect permite estructurar, de una forma más amigable, dichas estrategias facilitando al usuario la parametrización y la ejecución de los procesos.
- eCognition Server: Es el módulo que permite procesar grandes conjuntos de datos. Puede dividir el proyecto en partes más pequeñas que se ejecutan individualmente en distintos servidores o computadores y que se unen posteriormente. Incorpora también una extensión para ArcGis que aumenta las funcionalidades de ArcCatalog y ArcMap con aplicaciones de análisis automático de imágenes.
- eCognition Essentials: Módulo de manejo simplificado que permite realizar tareas de clasificación de forma rápida y efectiva. Con una interface amigable y simplificada, eCognition Essentials reduce los errores en el análisis ya que aplica algoritmos predefinidos y estructurados para analizar y transformar imágenes en información geoespacial relevante.

Para este manual hemos optado realizar el proceso metodológico en base a la versión eCognition Developer debido a que se ha considerado que el usuario entienda el funcionamiento, bondades y limitaciones de cada algoritmo en su aplicación. Cabe mencionar que la versión Essentials posee reglas predefinidas y estructuradas para el análisis de imágenes de satélite, pero se limita a un entendimiento global y jerárquico del proceso.

El proceso básico de eCognition es la segmentación. El proceso de segmentación es una técnica patentada para la creación de objetos de imágenes, evaluando los píxeles en contexto con sus pares. La forma, tamaño, color y compactibilidad son considerados y medidos de forma distinta en base a los parámetros introducidos por el usuario para generar segmentos.

Finalizado este curso básico de eCognition, el alumno estará apto para realizar tareas de análisis orientado a la clasificación de imágenes “Rapid Eye”, este análisis será en base a segmentos con una regla de trabajo que permite un análisis rápido y confiable.

## 1. Antecedentes del eCognition

El software eCognition fue desarrollado por la empresa Definiens en Alemania y utilizado inicialmente para la ciencia médica. El premio nobel Dr. Gerd Binnig desarrolló la patentada tecnología de red cognitiva (Cognition Network Technology) que es un método computacional para la extracción de información desde imágenes utilizando objetos de imágenes (grupos de píxeles) en lugar de los tradicionales métodos de procesamiento de píxeles; este método es conocido como la segmentación de imágenes. El poder detrás de esta tecnología radica en su capacidad de transformar, de manera rápida y fácil, el conocimiento y experiencia en rutinas automáticas.

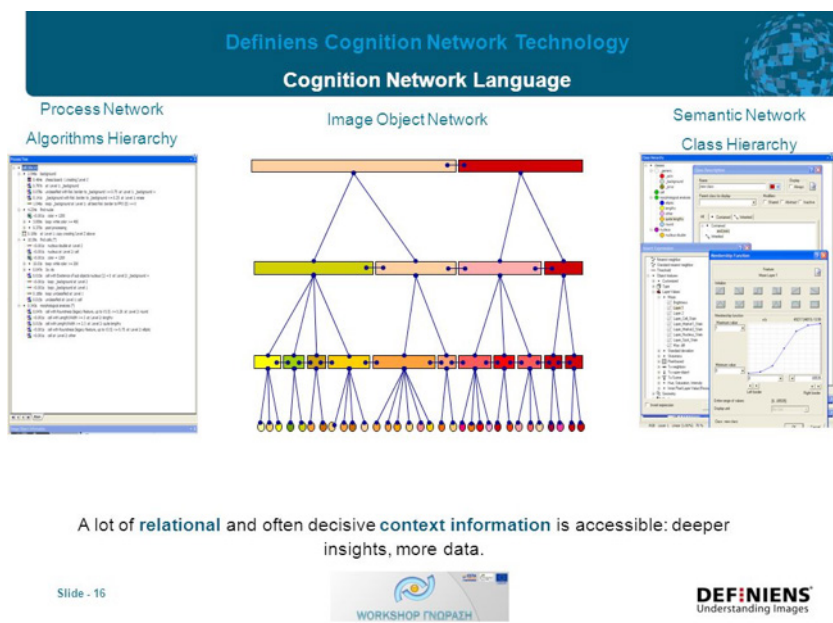


Figura 96. Tecnología de red cognitiva

## 2. Características espectrales de la imagen RapidEye

Las imágenes RapidEye, de propiedad de la compañía Planet Labs, se obtienen de una constelación conformada por cinco satélites, que toman imágenes con una resolución espacial de 6,5 metros y post procesadas generan imágenes con una resolución de 5 metros. Todos los satélites llevan consigo sensores idénticos, que están calibrados por igual y viajan en el mismo plano orbital (a una altitud de 630 km). Juntos son capaces de recoger, todos los días, más de 4 millones de km<sup>2</sup> de imágenes multiespectrales a color.

**Tabla 9.-** Características de las imágenes Rapid Eye

Atributo	Descripción
Formato de imagen	Archivo GeoTIFF Metadato en formato XML
Orientación del producto	Orientado al Norte
Recorte del producto	Recortes fijos a nivel mundial, en un sistema de malla de 24x24 km, con una sobreposición de 500 m para producir un archivo de 25x25 km. El excedente se rellena con negros
Espaciamiento del pixel	6.5 m y 5m
Tamaño del producto	25 km (500 líneas) por 25 km (5000 renglones) 250 Mb por recorte con 5 bandas.
Correcciones geométricas	Ortorectificación usando GCP y MDE fino
Datum Horizontal	WGS84
Proyección cartográfica	UTM (Universal Transversa de Mercator)
Método de remuestreo	Convolución cúbica (por defecto), MTF o Vecino más cercano
Bandas	5 bandas: Azul (Blue)                      440 – 510 m Verde (Green)                    520 – 590 m Rojo (Red)                        630 – 685 m Rojo límite (Red Edge)        690 –730 m Infrarrojo cercano (NR)        760 – 850 m
Resolución radiométrica	12 bits


**Fuente:** Instituto Nacional de estadística e informática – INEGI

**Tabla 10.-** Productos de las imágenes Rapid Eye

RapidEye Mosaics™ (Nivel 3M)	RapidEye Producto Ortoregado (Nivel 3A)	RapidEye Producto Básico (Nivel 1B)
<p>Los RapidEye Mosaics™ incorporan imágenes a color RapidEye que son ortorectificadas y equilibradas radiométricamente, y luego ensambladas para crear una sola imagen para áreas extensas, sin costuras visibles.</p> <p>Para mayor información favor revisar la sección de <b>Mosaicos</b>.</p>	<p>Correcciones radiométricas, geométricas y del sensor son aplicadas a los datos. Todos los productos han sido ortorectificados empleando un DEM SRTM DTED de nivel 1 o superior, y con el control terrestre apropiado se puede obtener una precisión de 6 m 1-sigma (12,7 m CE90). La mayor precisión alcanzada por estos productos corresponde a los estándares 1:25.000 NMAS.</p>	<p>Este nivel de corrección mínima es ideal para clientes que deseen procesar sus imágenes con sus propios datos para los GCPs/DEM/DSM (p.ej <b>NEXTMap</b>) y/o software p.ej <b>PCI Geomatica</b> o <b>GXL</b>.</p>

**Fuente:** Geosoluciones portal web: <http://www.geosoluciones.cl/rapideye/>

Las imágenes RapidEye cuentan con cinco bandas espectrales, tres en el espectro visible (rojo, verde y azul), una en el infrarrojo cercano y una banda en el segmento del rojo lejano (Red Edge), las cuales permiten captar las variaciones en la clorofila de la vegetación, lográndose así la separación de las especies y el monitoreo de la salud de la vegetación.



**Figura 97.** Características espectrales para las coberturas.  
Fuente: Manual for satellite data Analysis eCognition.

### 3 Abrir el software Ecognition.

- A partir del menú principal de Windows dirigirse a la carpeta de programas.
- Buscar la carpeta Trimble y dar click en eCognition Developer 64.

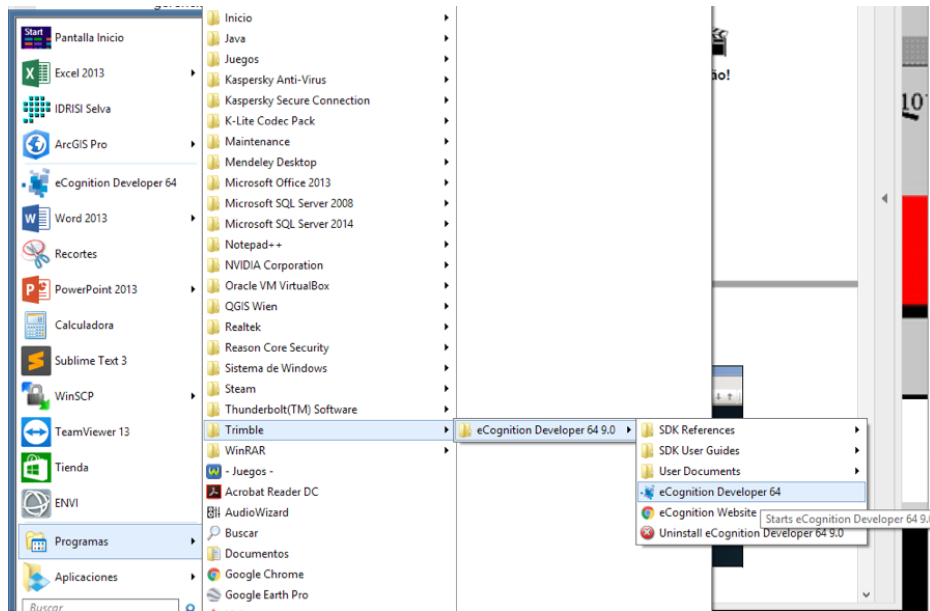


Figura 98. Apertura del software eCognition

Posterior a ello saldrá una ventana emergente y se seleccionara Rule Set Mode.

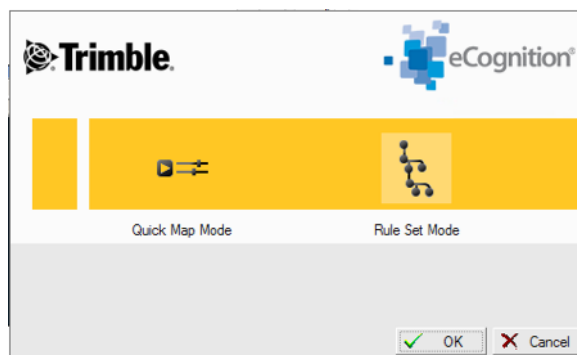


Figura 99. Selección del modo de trabajo

- Se abrirá el programa

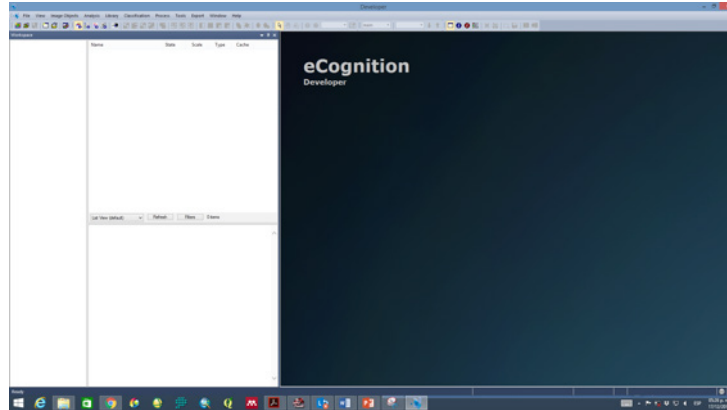


Figura 100. Visualización general del Software.

- Por defecto vienen modos de visualización predefinidos



Figura 101. Modulos de trabajo.

- 1.- Load and Manage data (cargar y administrar datos)
- 2.- Configure Analysis (Configurar análisis)
- 3.- Review Results (Revisar Resultados)
- 4.- Develop Rulesets (Desarrollar conjunto de reglas)\*

Para el desarrollo de este curso vamos a utilizar “Develop Rulesets”



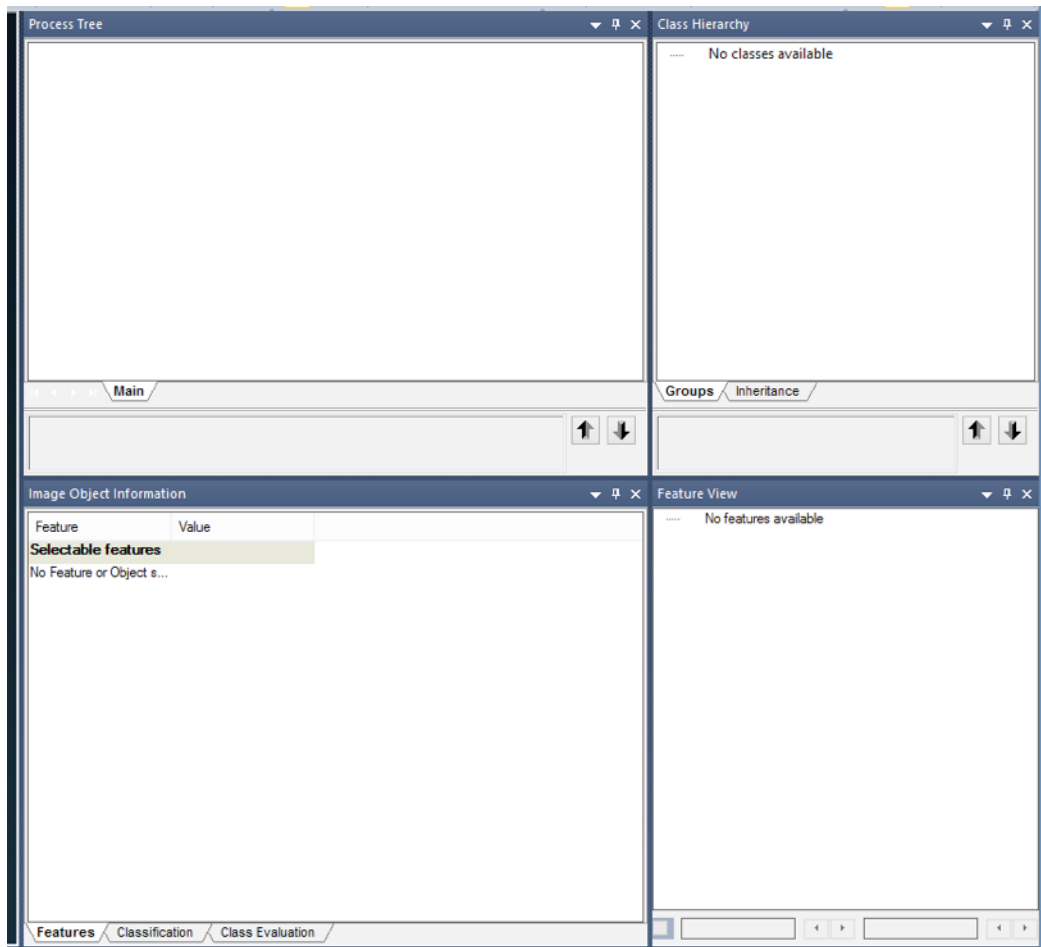


Figura 102. Interface de trabajo.

Interfaz de eCognition con las ventanas principales: visualización de los datos de imágenes en la ventana de la izquierda, menú y barra de herramientas en la parte superior y, a la derecha, las ventanas 'Process Tree', 'Class Hierarchy', 'Feature View' y 'Image Object Information'

#### 4 Visualizar objetos de una Imagen.

Los segmentos de imagen son los bloques de construcción para cualquier futuro análisis de imágenes y también comprenden el resultado final de la clasificación.

Hay varias formas de ver los objetos de imagen, su información o su clasificación. En la barra de herramientas 'View settings', se muestran las opciones de visualización de los objetos.



Tabla 11.- Visualización de Objetos

View Layer		Nos permite visualizar la imagen
Show or Hide Outlines		Nos permite ver contornos de los segmentos
Pixel view or Object Mean View		Nos permite ver los valores de los segmentos con respecto a la imagen

## 5 Visualizar los resultados de una Clasificación

Terminado el proceso de clasificación de una imagen, en base a los segmentos de una imagen, existen diferentes comandos que nos permiten interactuar los resultados con los segmentos e imagen base.

Tabla 12.- de la Clasificación

View Classification		Para poder utilizar esta función es necesario que “Hide Outlines” este desactivado.
Transparent / Non transparent outlined objects		Se puede ver de manera transparente los contornos de una imagen con una clasificación.

## 6 Otras funciones.

Para cambiar la escala de visualización en el desarrollo de la segmentación y clasificación de la imagen es necesario tener bien claro la escala de tamaño recomendada para las imágenes RapidEye. Para ello, nos vamos a ayudar con las siguientes herramientas:






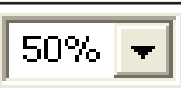

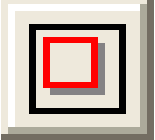


Figura 103. Interface de trabajo

Tabla 13.- Otras Funciones

	Cambio el cursor de modo Zoom o Pan a la forma predeterminada
	Permite desplazar de la imagen arrasándola de manera manual
	Permite Observar un área específica
	Disminuye la escala con respecto al centro de la visualización
	Aumenta la escala con respecto al centro de la visualización
	Selecciona el valor del Zoom.
	Visualiza toda el área del proyecto
	Permite definir el área que se va a visualizar moviendo un rectángulo a las diferentes regiones de la imagen. (Esta opción es importante para quienes trabajan con imágenes de grandes extensiones).

## 7 Ventanas esenciales para el desarrollo de conjunto de reglas

### 7.1 Image Object Information, Feature View (Información del objeto de la Imagen)

Las herramientas de *Feature View*, permite ver las características y valores que se utilizaran para la clasificación, estas características se asocian a los segmentos para luego ser utilizados en el proceso de clasificación. Para obtener información sobre toda la variedad de los valores relacionados con las características de un único objeto de imagen se utiliza la información del objeto de la imagen.

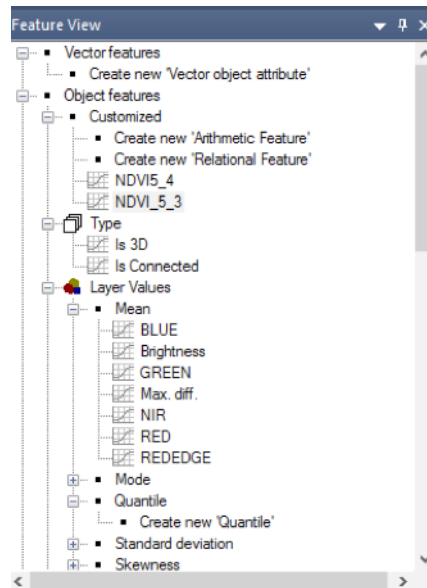


Figura 104. Índices y bandas de las imágenes

- La herramienta Image Object Information determina valores espectrales y de forma que se asocian a los segmentos. Estos valores son incluidos en el proceso de clasificación.

Feature	Value
<b>Image Object Relations</b>	
<b>Object features</b>	<b>Customized</b>
NDVI_5_3	0.063628
NDVI_5_4	0.057664
<b>Layer Values</b>	
<b>Mean</b>	
BLUE	28.63
Brightness	49.60
GREEN	45.32
Max. diff.	0.6889
NIR	62.80
REDEGE	55.95
RED	55.28
<b>Geometry</b>	
<b>Extent</b>	
Number of pixels	2531

Figura 105. Datos estadísticos de los segmentos

Nota: los valores determinados en Imagen Object Information dependen de los parámetros determinados en los segmentos, lo cual determina el tamaño de los mismos y, por consecuencia, los resultados de la clasificación. La sección de Información del Objeto de Imagen es un recurso poderoso de información sobre sus objetos de imágenes (conocidos como segmentos). Puede seleccionar diversos atributos de sus objetos para mostrarlos en esta ventana.

## 7.2 Class Hierarchy (Jerarquía de Clases)

Un paso clave para obtener resultados mediante una clasificación supervisada con eCognition es contar con muestras confiables (semillas).

Debido a que los segmentos son la base para una clasificación en eCognition, es necesario asociar estos segmentos con las semillas y con ello determinar las clases a clasificar. Para lograr esto existen diferentes métodos, estas clases pueden ser creadas mediante un archivo vector o muestras generadas por el usuario en la plataforma de eCognition.

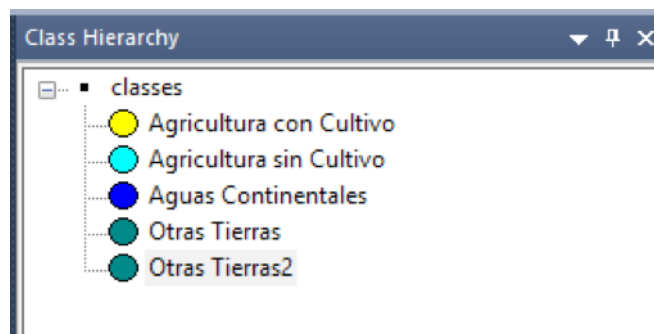


Figura 106. Árbol jerárquico de clases

Nota: Para este estudio de caso hemos optado por utilizar la experiencia del usuario para la toma de muestras. Hay que mencionar que las clases pueden ser jerárquicas con respecto a los objetivos del mapa a clasificar.

## 7.3 Process Tree (Árbol de procesos)

El árbol de procesos determina el flujo de trabajo a realizar en el módulo de eCognition Developer, cabe mencionar que el árbol de proceso permite realizar secuencias de procesos como también procesos aislados. Para el desarrollo de esta práctica y el entendimiento de los algoritmos utilizados en cada árbol de procesos, se ha decidido utilizar procesos individuales.

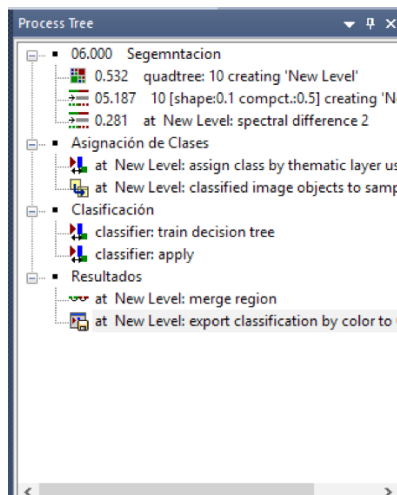


Figura 107. Árbol de procesos de algoritmos

La relación padres/hijos permite que el usuario construya el árbol de los procesos con procesos de padre que han anidado los procesos de hijos. Esto garantiza que “los procesos similares” estén agrupados en todo el Árbol del Proceso. Cuando se crea un padre es recomendable eliminar la selección de nombramiento automático y le dé al proceso un nombre lógico, ya que básicamente se está programando un contenedor para otros procesos.

## 8 Estudio de caso - Segmentación y Clasificación.

### Área costera (Departamento de Lima)

- Abrimos un proyecto en blanco de ecognition




Figura 108. Árbol jerárquico de clases

- Vamos a File New Project.

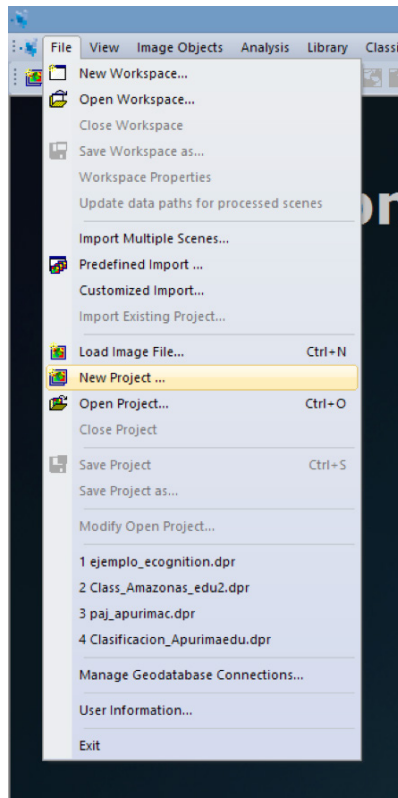


Figura 109. Nuevo Proyecto

- Nos dirigimos a la carpeta donde hemos guardado la imagen

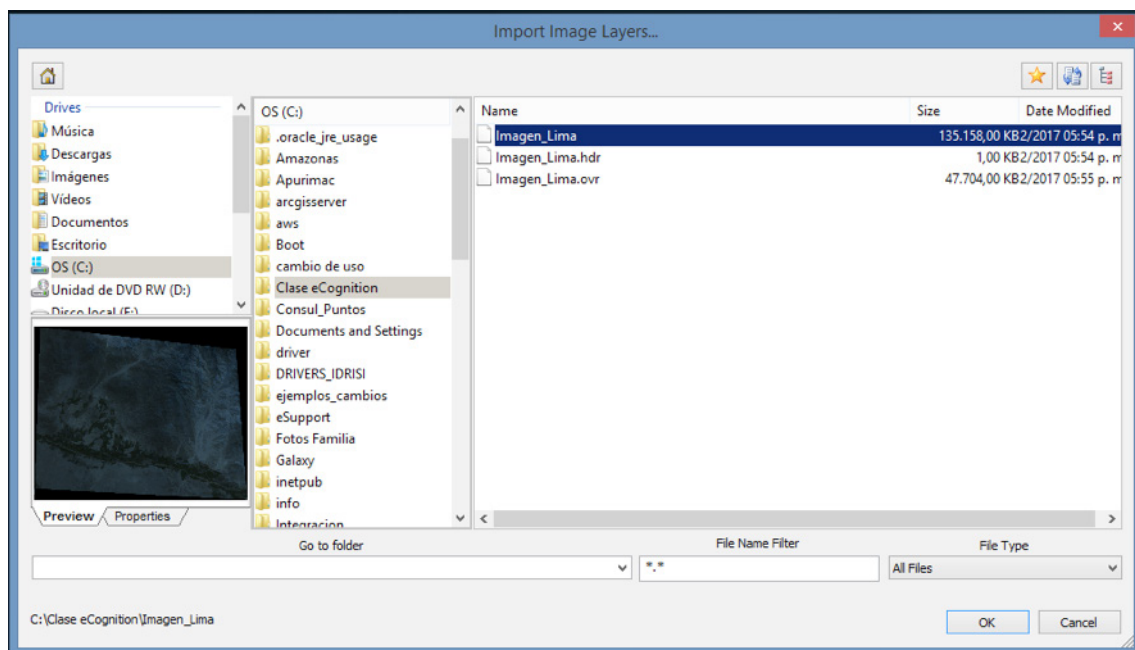


Figura 110. Carpeta de la Imagen

## “Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales”

- Vemos si están cargados todas las bandas, la resolución espacial y si el sistema de coordenadas es el correcto.

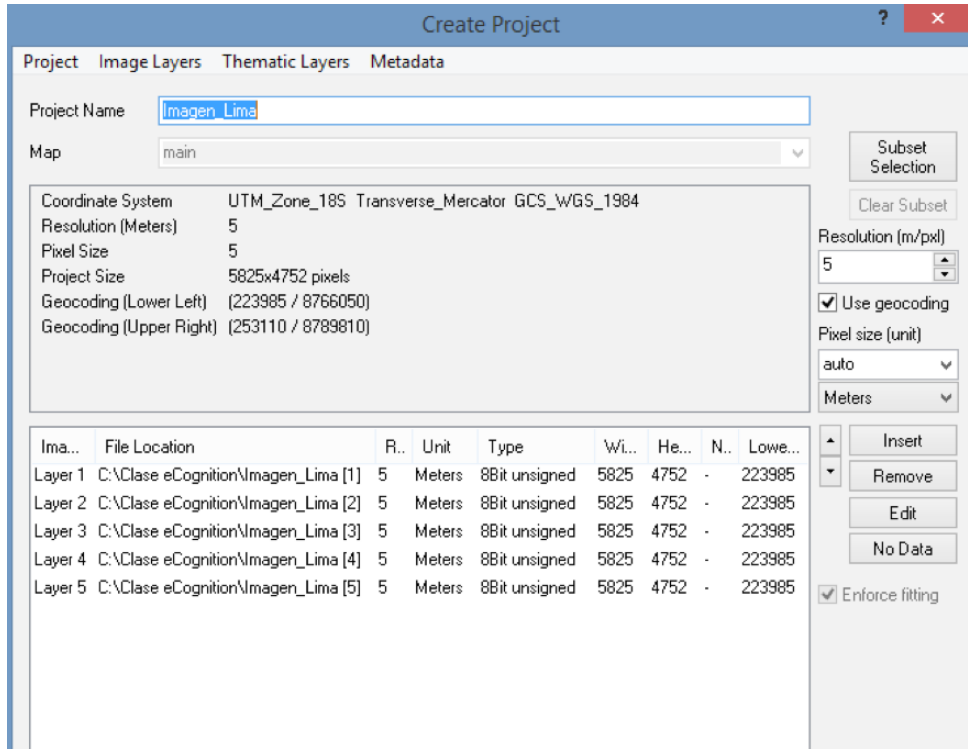


Figura 111. Características de la imagen a trabajar

- Procedemos a cambiar los nombres de las Bandas. Para ello hacemos seleccionamos las bandas y hacemos click en editar




Figura 112. Edición de nombres de las bandas



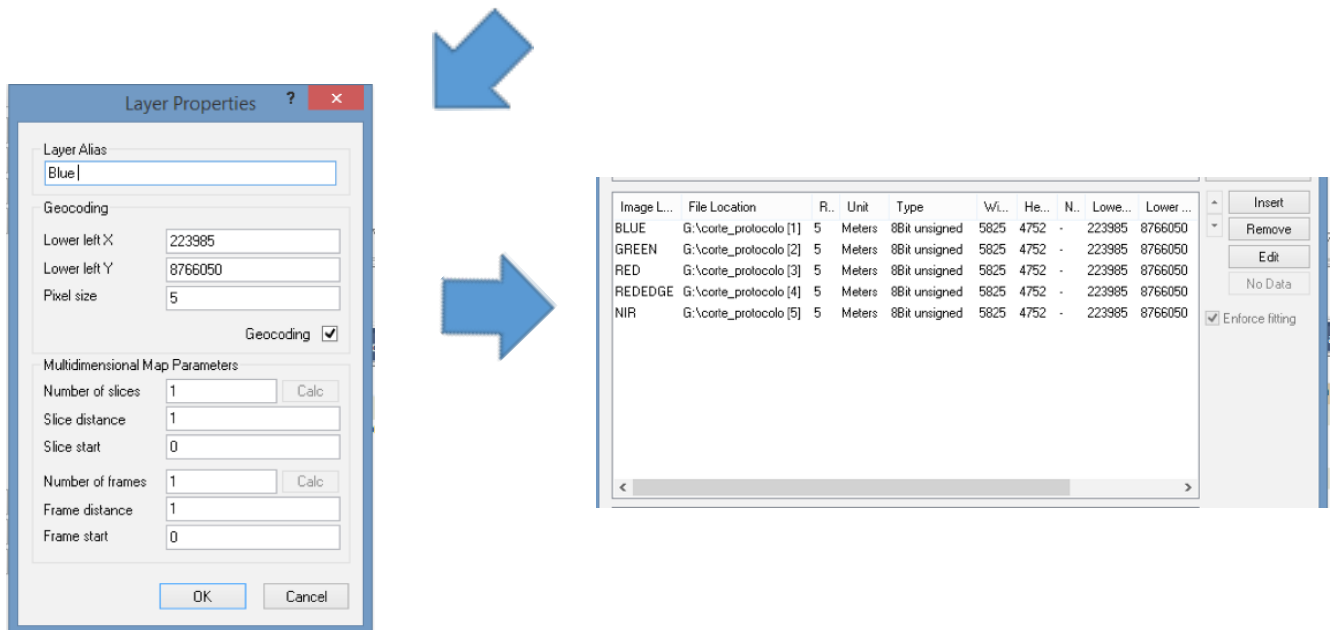


Figura 113. Edición de nombres de las bandas

- Click en Ok para finalizar la creación del proyecto

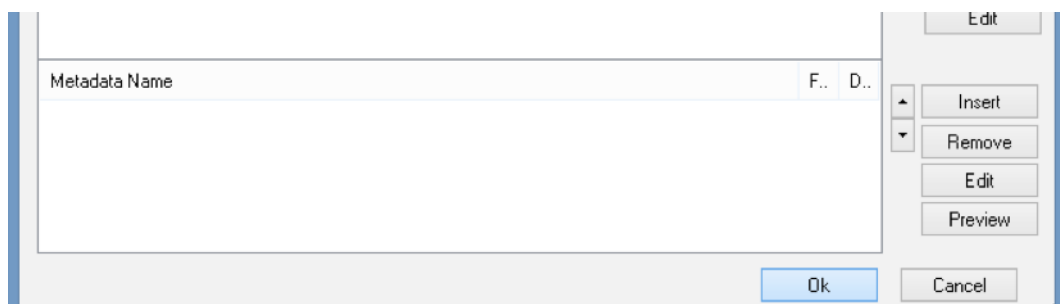


Figura 114. Creación de proyectos.

- Procedemos a visualizar la imagen por defecto




Figura 115. Visualización por defecto de la imagen.

- Composición de bandas: Procedemos a modificar la combinación de bandas en donde se realce la vegetación, para ello vamos a modificar la composición de las bandas espectrales de la siguiente forma:

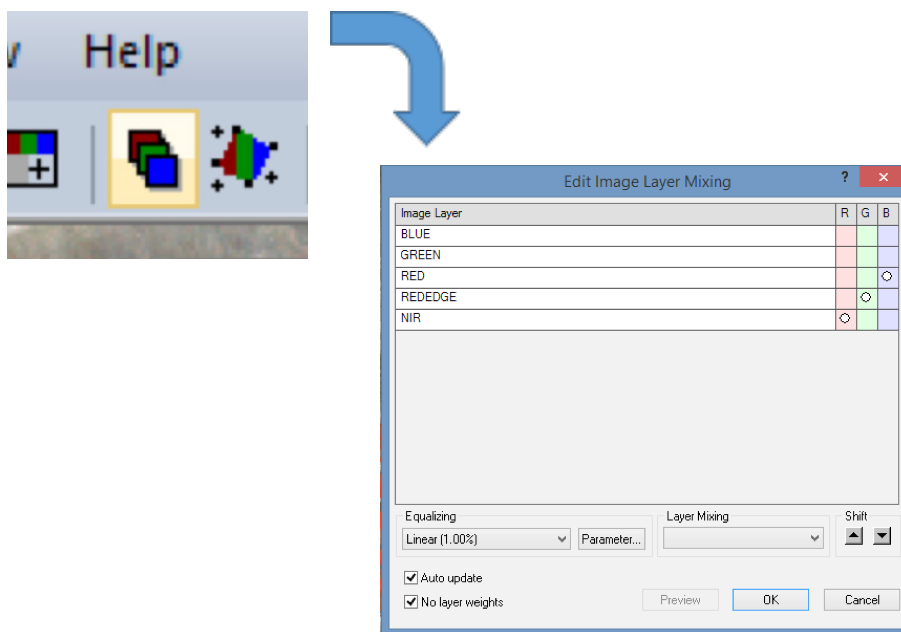


Figura 116. Cambio de la combinación de bandas para la visualización




Figura 117. Combinación de Bandas RGB 543

- Procedimiento de clasificación: Nos dirigimos a la ventana de Árbol de procesos y utilizamos las siguientes opciones para iniciar el proceso de clasificación:

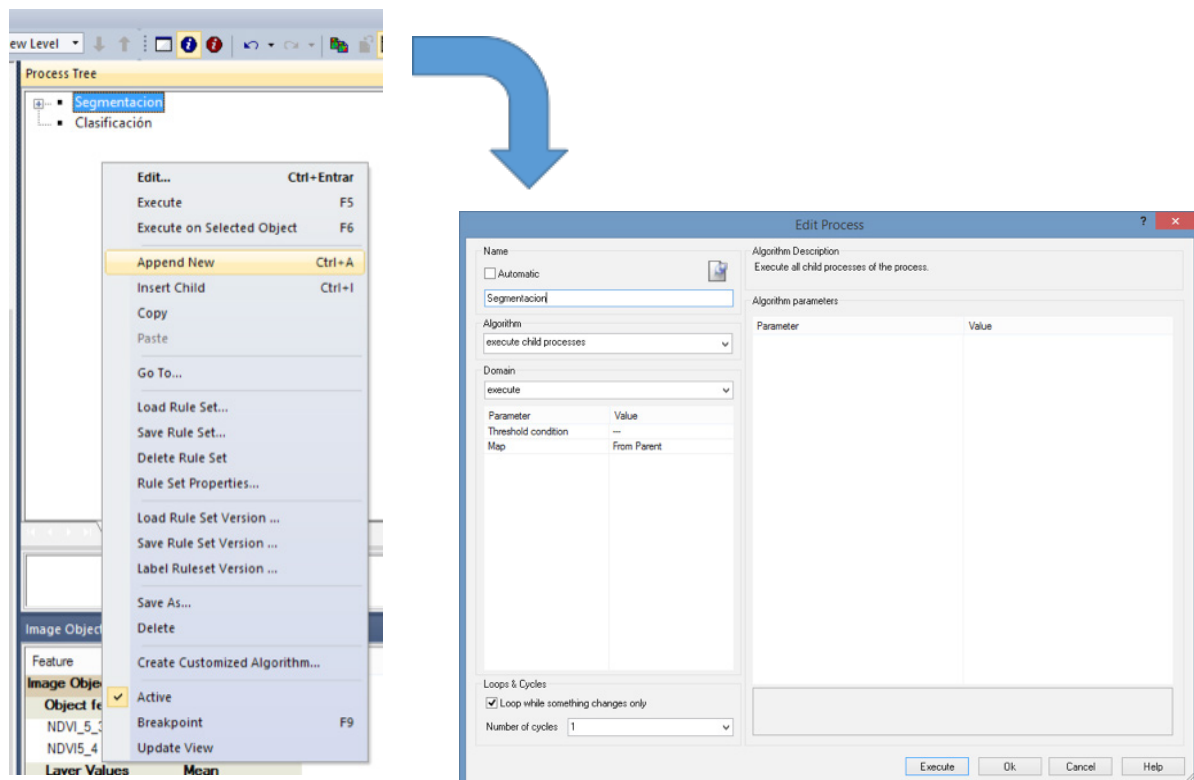


Figura 118. Generación del Árbol de Procesos

Las imágenes de alta resolución, clasificadas a nivel de píxeles, pueden mostrar un notable efecto sal y pimienta. Para corregir este problema (y la larga duración para clasificar amplias bases de datos de alta resolución), los objetos pueden ser creados reduciendo la variación espectral local, debido a texturas en corona, espacios, sombras, etc.

La idea es, en primer lugar, agrupar los píxeles similares y adyacentes espacialmente en objetos homogéneos espectralmente, y luego llevar a cabo la clasificación de objetos/segmentos como las unidades mínimas de procesamiento.

## 8.1 Proceso de segmentación

### 8.1.1 Segmentación

El proceso de segmentación de imágenes no examina los píxeles de forma aislada, sino en conjunto con los píxeles que los rodean. Este análisis es más similar al proceso humano vista-cerebro en el que construimos una imagen de manera iterativa, reconociendo los grupos de píxeles como objetos (campos, árboles, agua, etc). El análisis basado en objetos puede utilizar la forma y tamaño de los objetos y su contexto con relación a otros objetos para sacar conclusiones de manera similar a un analista experimentado. Para generar la segmentación nos apoyaremos en el algoritmo “multiresolution segmentation”

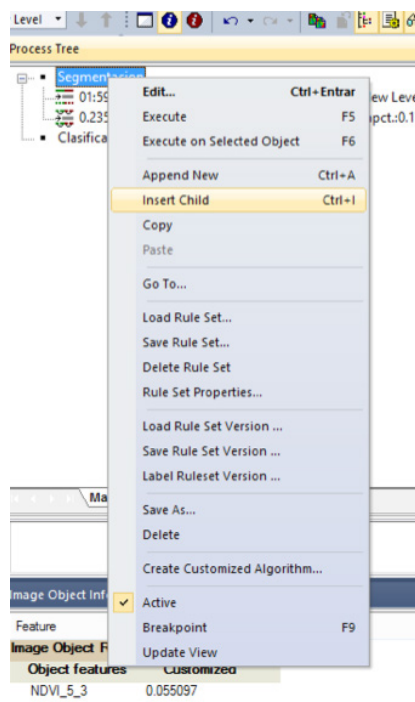


Figura 119. Algoritmo de segmentación

Determinamos diferentes parámetros para el proceso de segmentación los cuales son los siguientes:

- o Algoritmo: multi-resolution segmentation
- o Image object Domain: Pixel level:
- o Pesos de las bandas: Blue 1 Green 1 Red 1 rededgeE2 NIR 2
- o Thematic layer usage: No
- o Set scale parameter: 25
- o Shape 0.3 compactness 0.1

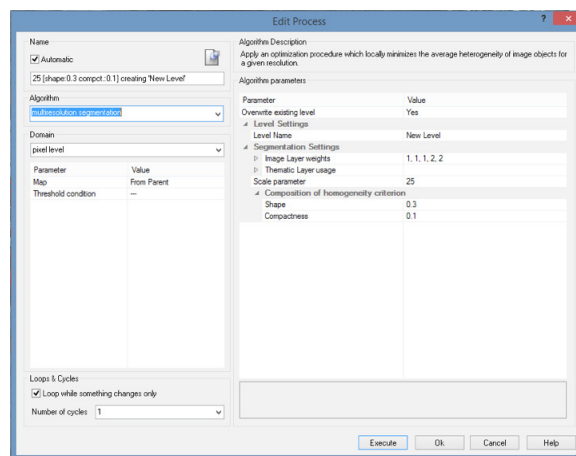


Figura 120. Parámetros de la segmentación

## 8.1.2 Segunda Segmentación

Para juntar los segmentos realizados nos apoyaremos en el algoritmo “multiresolution segmentation región grow”

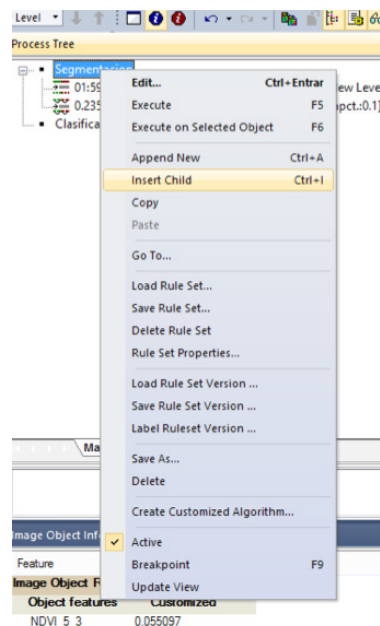


Figura 121. segunda segmentación

Determinamos diferentes parámetros para el proceso de segmentación los cuales son los siguientes:

- o Algoritmo: multi-resolution segmentation region grow
- o Image object Domain: Pixel level:
- o Pesos de las bandas: Blue 1 Green 1 Red 1 rededgeE2 NIR 2
- o Thematic layer usage: No
- o Set scale parameter: 50
- o Shape 0.3 compactness 0.1

## **8.2 Proceso de Clasificación**

Parte de las ventajas de realizar una clasificación en base a segmentos es que los segmentos filtran el “ruido” o la información irrelevante presente en cada uno de los píxeles y los agrupa para mostrar características reconocibles. Puede aumentar la precisión de la clasificación sobre la clasificación basada en píxeles. Elimina el efecto “sal y pimienta” que se da en la clasificación basada en píxeles.

Como parte de la clasificación, primero vamos a incluir las clases que deseamos clasificar (coberturas), seleccionamos las semillas (muestras de entrenamiento) y métodos de clasificación en base a diferentes algoritmos.

### **8.2.1 Inclusión de clases**

Como parte del proceso de clasificación es necesario tener los tipos de cobertura o usos que se requieren clasificar, para estos tipos de usos se pueden generar en la ventana class hierarchy de la siguiente manera.

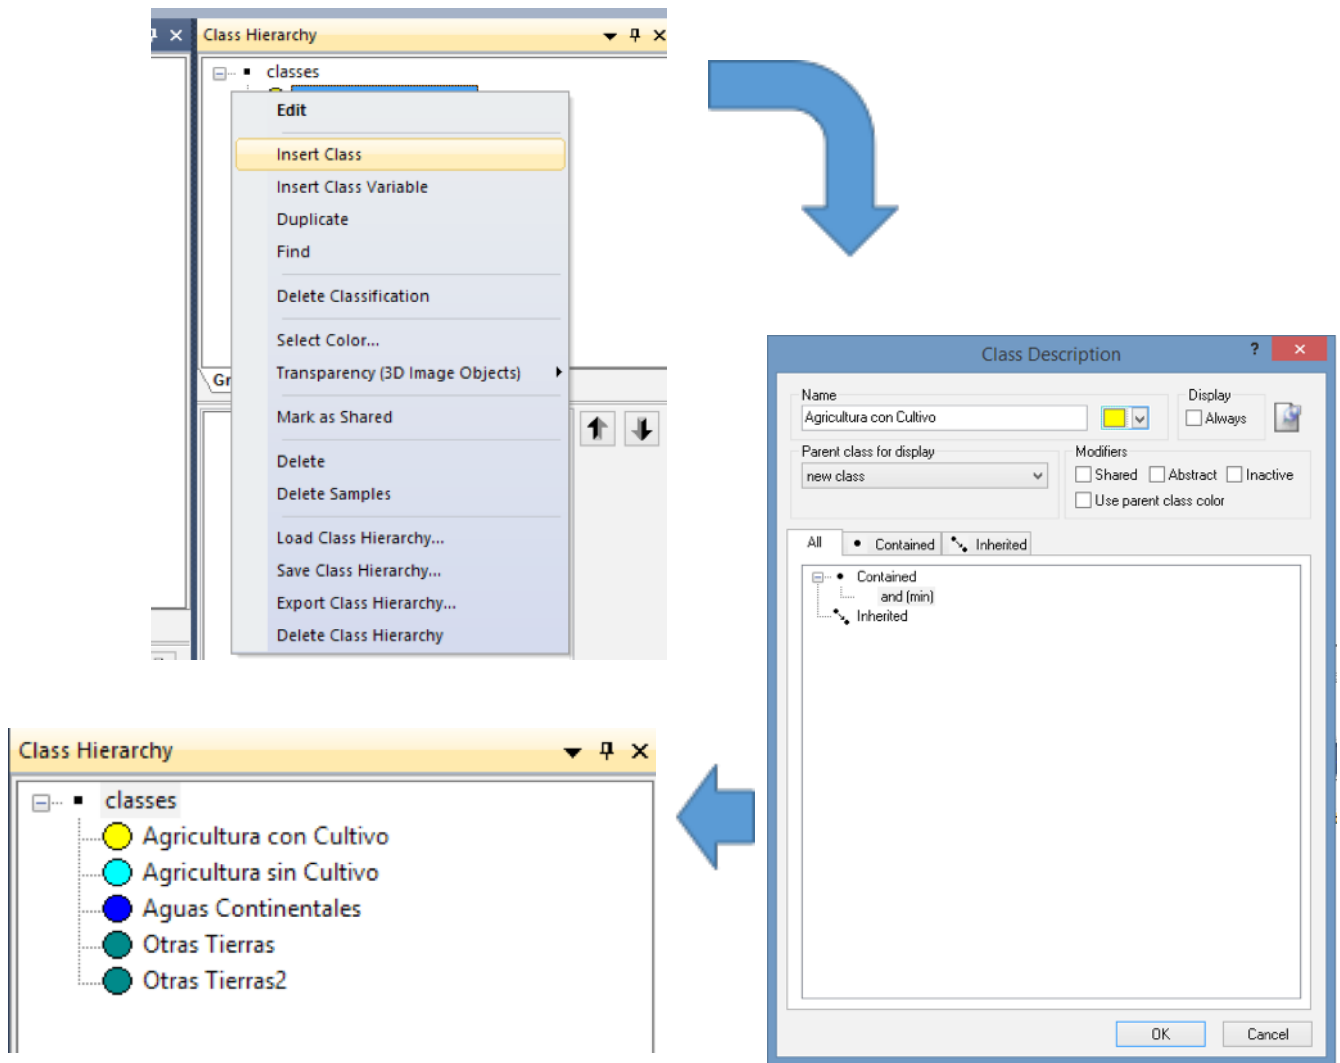


Figura 122. Clases a Clasificar

### 8.2.2 Toma de muestras

Para la toma de muestras se procede a activar la toma de muestras (semillas) para ello nos dirigimos a la pestaña clasificación luego a Samples y activamos Select Samples.

## “Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales”

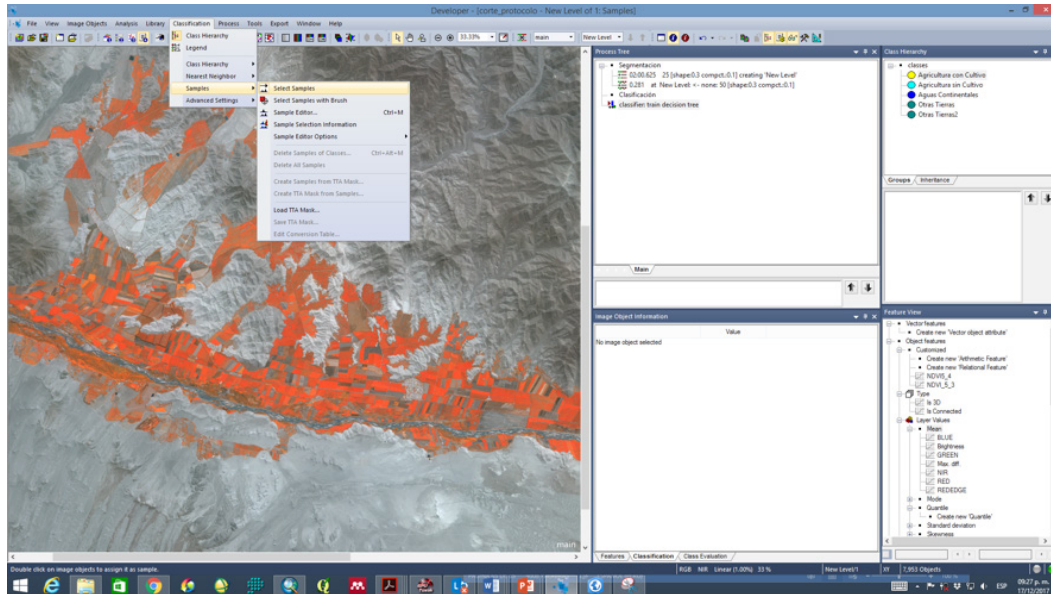
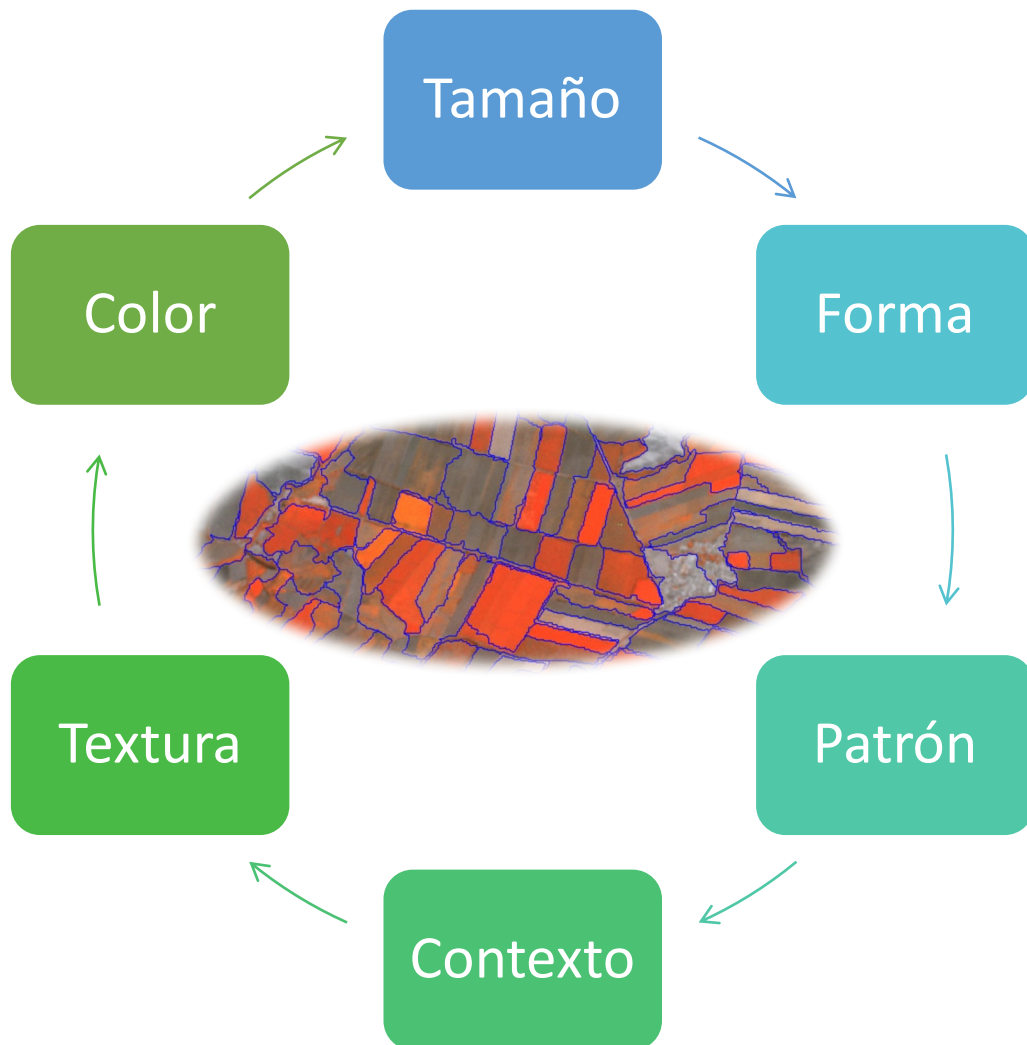


Figura 123. muestreo de semillas

Para la toma de muestras de las coberturas o clases es necesario seguir algunos criterios que se obtienen de las propiedades de la imagen, estos criterios más representativos y que permiten una mejor selección de muestras son los siguientes:





**Figura 124.** Variables a considerar para la toma de muestras

### 8.2.3 Proceso de clasificación

Es un proceso automatizado, el cual permite categorizar las coberturas, usos, entre otros, ya sea por píxeles u objetos de imagen en clases temáticas.

En este caso se va realizar una clasificación basado en segmentos, en donde se utiliza de base umbrales o agrupamientos estadísticos.

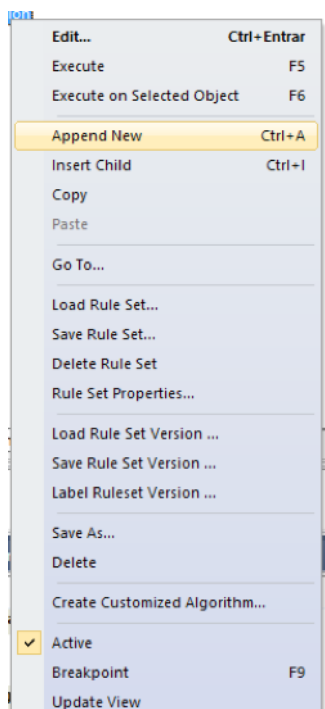


Figura 125. Ingreso de algoritmos para la segmentación

Como parte del proceso de clasificación vamos a añadir los algoritmos de clasificación dos veces. En la primera se determinará los parámetros y en la segunda la ejecución de los parámetros.

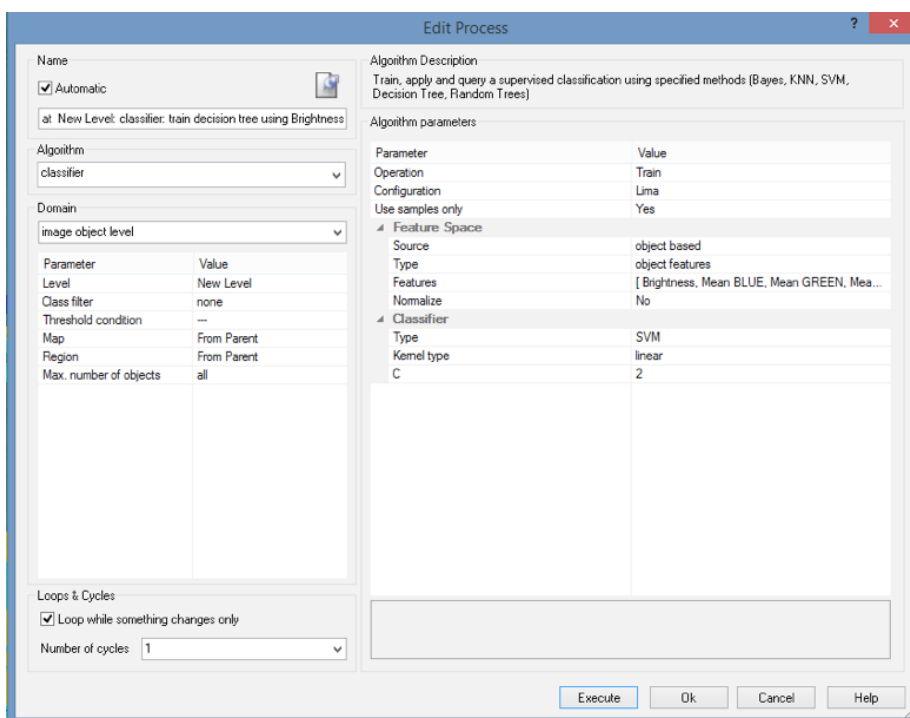


Figura 126. Parámetros para la Clasificación

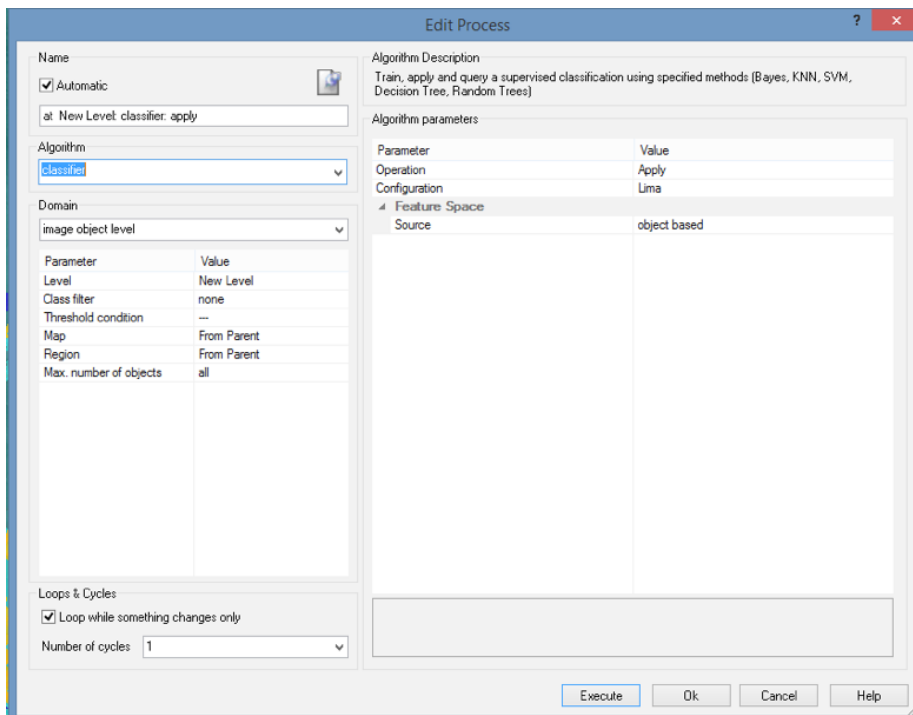


Figura 127. Parámetros de la aplicación de la segmentación




Figura 128. Resultados de la clasificación

### 8.2.4 Exportación de resultados

Como final del proceso de clasificación en eCognition se debe exportar los resultados. Para este proceso existe la opción de hacerlo a nivel de segmento o como imagen de clasificación.

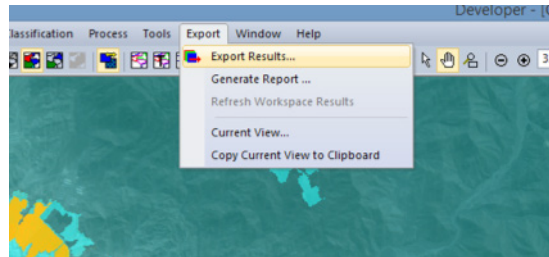


Figura 129. Exportar resultados

Tabla 14. Parámetros y formatos para exportar los resultados

Exportación de resultados	Parámetros
	<ul style="list-style-type: none"> <li>○ Export Type: Raster File</li> <li>○ Content Type: Clasificación</li> <li>○ Format: Erdas Images (*.img)</li> <li>○ Level: New Level</li> <li>○ Clases: clases clasificadas</li> </ul>
	<ul style="list-style-type: none"> <li>○ Export Type: Shapefile</li> <li>○ Content Type: Polygon raster</li> <li>○ Format: shapefile</li> <li>○ Level: New Level</li> <li>○ Clases: clases clasificadas</li> <li>○ Features: Class Names</li> </ul>



