



COLEGIO DE POSTGRADUADOS
INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS
AGRÍCOLAS

CAMPUS MONTECILLO

POSTGRADO EN HIDROCIENCIAS

**CLASIFICACIÓN SUPERVISADA DE CULTIVOS AGRÍCOLAS USANDO
IMÁGENES DE SATELITE TIPO RAPIDEYE EN EL DISTRITO DE RIEGO 017,
REGIÓN LAGUNERA.**

JOSE MANUEL ESPINOSA HERRERA

TESIS

**PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:**

MAESTRO EN CIENCIAS




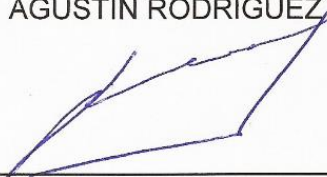
MONTECILLO, TEXCOCO, ESTADO DE MÉXICO.

2014

La presente tesis, titulada: **Clasificación supervisada de cultivos agrícolas usando imágenes de satélite tipo rapideye en el Distrito de Riego 017, Región Lagunera**, realizada por el alumno: **José Manuel Espinosa Herrera**, bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS
HIDROCIENCIAS

CONSEJO PARTICULAR

CONSEJERO:	 _____
	DR. ROBERTO ASCENCIO HERNÁNDEZ
ASESORA:	 _____
	DRA. ANTONIA MACEDO CRUZ
ASESOR:	 _____
	DR. AGUSTÍN RODRÍGUEZ GONZÁLEZ
ASESOR:	 _____
	M.C FELIPE JOSÉ ANTONIO PEDRAZA OROPEZA

Montecillo, Texcoco, México, julio de 2014

RESUMEN

CLASIFICACIÓN SUPERVISADA DE CULTIVOS AGRÍCOLAS USANDO IMÁGENES DE SATELITE TIPO RAPIDEYE EN EL DISTRITO DE RIEGO 017, REGIÓN LAGUNERA

José Manuel Espinosa Herrera, M.C.

Colegio de Postgraduados, 2014

Identificar los cultivos y estimar su superficie cultivada es información muy valiosa para la toma de decisiones en políticas de apoyo económico a los productores y determinación del volumen de importación. En el presente estudio, se desarrolló una metodología utilizando clasificación supervisada para identificar cultivos agrícolas usando imágenes multiespectrales y multitemporales del satélite RapidEye. El método se basa en comparar la firma del cultivo a clasificar con una colección de firmas de diferentes cultivos tomando como punto de referencia la banda 4 (Borde Rojo) y discriminando en función de los valores de las bandas 2 (verde) y 3 (roja). La colección de firmas se obtuvo a partir de 70 parcelas de los cinco cultivos más importantes de la “Región Lagunera” (Durango-Coahuila, México) monitoreadas durante cuatro meses en un total de ocho imágenes de satélite, resultando en una colección total de 183 firmas espectrales. La metodología se validó sobre 545 parcelas y se evaluó la precisión mediante una matriz de confusión, obteniéndose una precisión global del 69.17 % y un coeficiente Kappa de 0.42. Esta metodología permite la identificación de cultivos apoyándose de una sola imagen de satélite sin la necesidad de realizar un muestreo en campo pues se dispone ya del banco de firmas. La mejor precisión (precisión del usuario) que se obtuvo para un cultivo fue de 92.16 %.

ABSTRACT

AGRICULTURAL CROP CLASSIFICATION SUPERVISED USING RAPIDEYE SATELLITE IMAGERY IN IRRIGATION DISTRICT 017 “REGIÓN LAGUNERA”

Crop identification and estimation of agricultural area are worth information to take suitable decisions in the policies to support financially to farmers and define the crop quantities to be imported. In this study, a method was developed for classifying agricultural crops using multi-spectral and multi-temporal RapidEye satellite images. The method is based in comparing the spectral signature of a crop against a collection of signatures of different crops taking as a reference point the band 4 (Red Edge) and discriminating on the bases of the values of the bands 2 (green) and 3 (red). The collection of signatures was obtained from 70 parcels of the five most important crops in the “Región Lagunera” (Durango-Coahuila, México) monitored during four months using eight satellite images, allowing to collect 183 spectral signatures. The proposed methodology was validated on 545 parcels and its accuracy was assessed using a confusion matrix, obtaining an overall accuracy of 69.17% and a Kappa coefficient of 0.42. This methodology allows the identification of crops with a single satellite image without using a field sampling because it already has all the signature collection. The best accuracy (user accuracy) obtained for a particular crop was 92.16%.

DEDICATORIA

A dios por permitirme conseguir un logro más en esta vida.

A mis padres Eleuterio Espinosa Flores y María Eugenia Herrera Ramírez por su apoyo total, amor y confianza.

A mi abuelo Martín Espinosa Rojas† y mi abuela Francisca Herrera Duran† quienes nos enseñaron predicando con el ejemplo que el trabajo es el mejor de los vicios.

A mis hermanos Israel, Edith y Aarón por su apoyo siempre incondicional.

A Arely Romero Padilla por su gran cariño pero sobre todo por alegría de tenerla presente en mi vida.

A mis tíos Marcelino, Isaiás Guillermo, Juan, Abel, Julio, Cruz, Ana Félix, Catalina Genoveva y Crispina quienes siempre me han motivado para lograr mi superación personal y profesional

A mis amigos que con sus pláticas, consejos y compañía hacen más gratos los días.

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el financiamiento de mis estudios de posgrado.

Al Colegio de Postgraduados por darme la oportunidad de realizar mis estudios de maestría.

Al Dr. Roberto Ascencio Hernández por todo el apoyo brindado durante mis estudios y para la culminación del presente trabajo.

A la Dra. Antonia Macedo Cruz por su invaluable apoyo como directora de tesis. Por toda la atención y esmerada revisión de este trabajo, por el tiempo dedicado y sobre todo por su confianza.

Al Dr. Agustín Rodríguez González por su amistad, el apoyo y la oportunidad de realizar este trabajo.

Al M.C. Felipe José Antonio Pedraza Oropeza, de quien aprendí los conocimientos y el interés por la percepción remota, por todas las sugerencias del presente trabajo.

A la Gerencia de Distritos de Riego de la Comisión Nacional del Agua (CONAGUA) y al Colegio Mexicano de Especialistas en Recursos Naturales (COLMERN) por toda la información brindada.

A Arely Romero, Emmanuel Roblero, Luis Nevarez y Adriana Silva por las valiosas aportaciones a este trabajo.

CONTENIDO

1. INTRODUCCIÓN.....	1
2. OBJETIVOS.....	3
2.1. General	3
2.2. Particulares	3
3. REVISION DE LITERATURA	4
3.1. Sistemas de información geográfica (SIG).....	4
3.1.1. Algunos productos SIG en el mercado	5
3.2. Percepción Remota o teledetección.....	6
3.2.1. Satélites.....	8
3.2.2. Sensores	9
3.2.3. Imágenes de satélite.....	11
3.3. Espectro Electromagnético	13
3.3.1 Rangos del espectro electromagnético.....	13
3.3.2 Firmas espectrales	14
3.4. Clasificación de imágenes.....	16
3.4.1 Método supervisado.	17
3.4.2 Método no supervisado	18
3.5. Corrección y transformación de imágenes.....	19
3.5.1 Corrección del bandeo de la imagen	20
3.5.2 Correcciones radiométricas	20
3.5.3 Restauración de líneas o pixeles perdidos	21
3.5.4 Corrección atmosférica.....	21
3.5.5 Corrección geométrica.....	23
3.6. Unidades de Muestreo	24
3.6.1 Un solo pixel	24
3.6.2 Grupo de Pixeles	26
3.6.3 Polígonos.....	28
3.7. Índices de vegetación.....	30
3.7.1 Índice de vegetación de diferencia normalizada (NDVI).....	34
3.7.2 Índice de vegetación de diferencia ponderada (WDVI).....	35

3.8.	Tipos de evaluación de exactitud	36
3.8.1	La matriz de error	36
3.8.2	Análisis Kappa	39
3.9.	Satélite RapidEye.....	41
4.	MATERIALES Y MÉTODOS.....	44
4.1.	Descripción del área de estudio	44
4.1.1	Ubicación.....	44
4.1.2	Clima	45
4.1.3	Vegetación.....	45
4.2.	Herramientas y software utilizado	46
4.3.	Metodología	47
4.3.1.	Adquisición de las imágenes	49
4.3.2.	Pre-procesamiento de imágenes.....	52
4.3.3.	Verificación de parcelas en campo.....	58
4.3.4.	Selección de parcelas de entrenamiento.....	59
4.3.5.	Asignación de los datos raster a los datos vectoriales	61
4.3.6.	Análisis de la información	62
4.3.7.	Elaboración del clasificador	65
5.	RESULTADOS Y DISCUSIÓN	72
5.1.	Comportamiento por cultivo	72
5.1.1	ALFALFA	72
5.1.2	ALGODÓN.....	75
5.1.3	MAIZ	78
5.1.4	NOGAL	82
5.1.5	SORGO	84
5.2.	Comparación entre cultivos.....	86
5.3.	Comparaciones multi-parcelas.....	87
5.4.	Análisis individual de las bandas espectrales a lo largo del ciclo.....	90
5.5.	Elaboración del clasificador.....	93
5.5.1	Comparación espectral maíz-sorgo	93
5.5.2	Comparación espectral sorgo-alfalfa	94

5.5.3	Comparación espectral sorgo-nogal	94
5.5.4	Comparación espectral sorgo-algodón	95
5.5.5	Comparación espectral maíz-nogal	95
5.5.6	Comparación espectral nogal-algodón.	96
5.5.7	Comparación espectral nogal-alfalfa	96
5.5.8	Comparación espectral maíz algodón	97
5.5.9	Comparación espectral maíz alfalfa.....	97
5.5.10	Comparación espectral alfalfa-algodón	98
5.6.	Matriz de confusión	100
5.6.1.	Índice Kappa.....	101
5.7.	Mosaico de cultivos	102
6.	CONCLUSIONES Y RECOMENDACIONES.....	103
7.	LITERATURA CITADA	105
	ANEXOS	114

LISTA DE FIGURAS

Figura 1. Espectro electromagnético	14
Figura 2. Firmas espectrales típicas de la vegetación, agua y suelo	15
Figura 3. Comparación de la exactitud de evaluación de polígonos (píxeles homogéneos y píxeles heterogéneos).....	27
Figura 4. Evaluación de exactitud del polígono de referencia de bosque mixto sobre bosque siempre verde, mixto y bosque caducifolio.	29
Figura 5. Esquema de la línea del suelo..	32
Figura 6. Índices de vegetación basados en la pendiente.....	32
Figura 7. Índices de vegetación basados en la distancia	33
Figura 8. Ejemplo de matriz de error	37
Figura 9. Zona de estudio.....	44
Figura 10. Vegetación predominante en el Distrito 017, Región Lagunera	46
Figura 11. Fases para obtener el clasificador.....	48
Figura 12. Imagen utilizada para cubrir el área del módulo X Masitas.	49
Figura 13. Imágenes RapidEye adquiridas	51
Figura 14. Importación de imágenes usando ERDAS	52
Figura 15. Georreferenciación usando Autosync de ERDAS	53
Figura 16. Archivo metadata de imagenes RapidEye	55
Figura 17. Modelo de reflectancia en ERDAS.....	56
Figura 18. Valor mínimo de la banda 1 (10.285) para la imagen del 22 de abril ...	57
Figura 19. Modelo de sustracción de objetos oscuros en ERDAS	58
Figura 20. Modificación del shapefile para ajustar la dimensión de las parcelas ..	60
Figura 21. Recorte aplicado a las parcelas seleccionadas.....	60
Figura 22. Asignación de datos raster al vector usando "ZONAL ATTRIBUTES" .	61
Figura 23. Datos trasladados a excel	62
Figura 24. Etapa 1 del clasificador	66
Figura 25. Etapa 2 del clasificador para los cultivos de maíz, sorgo y algodón. ...	67
Figura 26. Etapa 2 del clasificador para los cultivos de nogal y alfalfa.....	68
Figura 27. Etapa 3 del clasificador	69
Figura 28. Etapa 4 del clasificador.	70

Figura 29. Etapa 5 del clasificador	71
Figura 30. Firmas espectrales de la alfalfa.....	72
Figura 31. Comportamiento del WdVI a lo largo del ciclo de una parcela de alfalfa	73
Figura 32. Seguimiento de la parcela de alfalfa.	74
Figura 33. Firmas espectrales del algodón.	75
Figura 34. Comportamiento del WdVI a lo largo del ciclo de una parcela de algodón.	76
Figura 35. Firmas espectrales del algodón a WdVI superior a 5	76
Figura 36. Seguimiento de la parcela de algodón.	77
Figura 37. Firmas espectrales del maíz.	78
Figura 38. Comportamiento del WdVI a lo largo del ciclo de una parcela de maíz.	79
Figura 39. Comportamiento del WdVI a lo largo del ciclo de una parcela de maíz (abril 2013).	79
Figura 40. Comportamiento del WdVI a lo largo del ciclo de una parcela de maíz (mayo-julio 2013).....	80
Figura 41. Firmas espectrales del maíz a WdVI superior a 4	81
Figura 42. Comparación de firmas de parcelas del nogal	82
Figura 43. Firmas espectrales del sorgo	84
Figura 44. Comportamiento del WdVI a lo largo del ciclo de una parcela de sorgo	84
Figura 45. Seguimiento de la parcela de sorgo.	85
Figura 46 Comportamiento de los cinco cultivos	86
Figura 47. Comparación de firmas espectrales de los cinco cultivos	87
Figura 48. Comportamiento del WdVI en cuatro parcelas	88
Figura 49. Comparación parcelas de maíz.....	88
Figura 50. Comparación de firmas en fase de crecimiento y senescencia.....	89
Figura 51. Diferencias espectrales a mismos valores de WdVI en maíz	90
Figura 52. Evolución de los valores de reflectancia.	91
Figura 53. Relación entre la banda 4 y la banda 2 del maíz	92

Figura 54. Comparación maíz-sorgo	93
Figura 55. Comparación sorgo-alfalfa.	94
Figura 56. Comparación sorgo-nogal	94
Figura 57. Comparación sorgo-algodón.	95
Figura 58. Comparación maíz-nogal	95
Figura 59. Comparación nogal-algodón	96
Figura 60. Comparación nogal-alfalfa	96
Figura 61. Comparación maíz- algodón.	97
Figura 62. Comparación maíz- alfalfa.	97
Figura 63. Comparación alfalfa- algodón.	98
Figura 64. Reflectancia de la banda 4 de todos los cultivos.....	99
Figura 65. Mosaico de cultivos obtenidos en la clasificación	102

LISTA DE CUADROS

Cuadro 1. Valoración del coeficiente Kappa	41
Cuadro 2. Bandas Espectrales de la constelación RAPIDEYE	42
Cuadro 3. Descripción del equipo de campo utilizado.....	47
Cuadro 4. Archivos entregados con cada imagen Rapideye.....	49
Cuadro 5. Imágenes RapidEye utilizadas para cubrir la zona de estudio.	50
Cuadro 6. Parcelas muestreadas en campo.	59
Cuadro 7. Numero de parcelas por cultivo utilizados para en el análisis.	59
Cuadro 8. Comparación de valores de la banda 4 de parcelas de nogal (P1: Parcela 1, P2: Parcela 2, DIF: DIFERENCIA ABS: ABSOLUTA)..	83
Cuadro 9. Número de firmas obtenidas por cultivo.	99
Cuadro 10. Matriz de confusión de la clasificación.....	100

SIMBOLOS

B1_P: Valor promedio de la Banda 1 (Azul) en la parcela a clasificar

B2_P: Valor promedio de la Banda 2 (Verde) en la parcela a clasificar

B3_P: Valor promedio de la Banda 3 (Rojo) en la parcela a clasificar

B4_P: Valor promedio de la Banda 4 (Borde Rojo) en la parcela a clasificar

B5_P: Valor promedio de la Banda 5 (Infrarrojo Cercano) en la parcela a clasificar

ABS: Diferencia absoluta entre el valor de dos bandas

B4_i : Valor i de la banda 4 (Borde Rojo) contenida en el banco de firmas del cultivo

B4_{i+1} : Valor siguiente de la banda 4 (Borde Rojo) contenida en el banco de firmas del cultivo.

B4_{n-1} : Penúltimo valor de la banda 4 en el banco de firmas del cultivo.

B4_n : Ultimo valor de la banda 4 en el banco de firmas del cultivo.

B1_M : Valor de la banda 1 del maíz

B2_M : Valor de la banda 2 del maíz

B3_M : Valor de la banda 3 del maíz

B4_M : Valor de la banda 4 del maíz

B5_M : Valor de la banda 5 del maíz

B1_S : Valor de la banda 1 del sorgo

B2_S : Valor de la banda 2 del sorgo

B3_S : Valor de la banda 3 del sorgo

B4_S : Valor de la banda 4 del sorgo

B5_S : Valor de la banda 5 del sorgo

B1_{AN} : Valor de la banda 1 del algodón

B2_{AN} : Valor de la banda 2 del algodón

B3_{AN} : Valor de la banda 3 del algodón

B_{4AN} : Valor de la banda 4 del algodón

B_{5AN} : Valor de la banda 5 del algodón

B_{1N} : Valor de la banda 1 del nogal

B_{2N} : Valor de la banda 2 del nogal

B_{3N} : Valor de la banda 3 del nogal

B_{4N} : Valor de la banda 4 del nogal

B_{5N} : Valor de la banda 5 del nogal

B_{1AA} : Valor de la banda 1 de la alfalfa

B_{2AA} : Valor de la banda 2 de la alfalfa

B_{3AA} : Valor de la banda 3 de la alfalfa

B_{4AA} : Valor de la banda 4 de la alfalfa

B_{5AA} : Valor de la banda 5 de la alfalfa

ΣM : Suma del número de veces discriminado como maíz

ΣS : Suma del número de veces discriminado como sorgo

ΣAN : Suma del número de veces discriminado como algodón

ΣN : Suma del número de veces discriminado como nogal

ΣAA : Suma del número de veces discriminado como alfalfa

MAX: Número máximo.

ENC: Número de veces encontrado el número máximo (MAX)

MIN: Número mínimo

SUM: Suma

1. INTRODUCCIÓN

El uso de los sensores remotos para monitorear cultivos ha aumentado (Paz *et al.*, 2005) y las imágenes de satélite son una alternativa para poder estimar las condiciones de los cultivos en grandes regiones (Palacios y Flores, 2013), por lo que las diversas plataformas satelitales representan un herramienta de apoyo para la toma de decisiones (Manjarraez *et al.*, 2007).

Las imágenes de satélite son una importante fuente de información para caracterizar el uso del suelo (Alperin *et al.*, 2002), pero más allá de identificar si se trata de una tierra de cultivo se han desarrollado trabajos para distinguir de que cultivo se trata utilizando diversas técnicas de clasificación en distintas imágenes de satélite. Identificar los cultivos y estimar su superficie cultivada es información muy valiosa para la toma de decisiones en políticas de apoyo a los productores y determinación del volumen de importación (Rodríguez *et al.*, 2004).

El proceso de clasificación está condicionado por la disponibilidad de imágenes con la información espectral y por su resolución espacial (Fernández *et al.*, 2003). Actualmente hay varios de satélites de diferente resolución espacial, temporal, espectral y radiométrica apropiados para aplicaciones agrícolas (Manjarraez *et al.*, 2007) y uno de ellos es el satélite RapidEye conformado por una constelación de cinco satélites idénticos (George *et al.*, 2005) con una capacidad de revisita diaria y una resolución espacial de 6.5 m, y además ofrecen cinco bandas espectrales (azul, verde, rojo, borde rojo y el infrarrojo cercano), la banda de borde rojo la cual se encuentra en la zona de transición entre la reflectancia mínima (rojo) y máxima (infrarrojo cercano) puede ser utilizada en la medición del tipo, la edad y estado de la vegetación (Bindel *et al.*, 2011).

Uno de los métodos más eficaces para distinguir los objetos presentes en una imagen a bordo de una plataforma satelital consiste en el estudio de su firma espectral (Ramirez *et al.*, 2010). La firma espectral describe la fracción de radiación incidente que es reflejada de la superficie en función de la longitud de onda. La firma

espectral de los cultivos agrícolas está influenciada por la presencia de pigmentos como es la clorofila y carotenoides, estos contenidos dependen de la actividad biológica y química de la planta (Moroni *et al.*, 2013).

La clasificación de firmas usando una sola imagen tiene la desventaja de comparar las firmas en diferente etapa de crecimiento (Oliveira *et al.*, 2003). La firma dependerá de la fecha en que sea tomada la imagen por lo que la fecha de adquisición de la imagen es importante en estudios de vegetación (Cole *et al.*, 2014).

La clasificación convencional de imágenes de satélite se basa en la asignación de los píxeles individuales a determinadas clases temáticas (Volante *et al.*, 2007). En los últimos años algunos estudios han demostrado que la clasificación basada en objetos ofrece un mejor análisis que la clasificación por píxel (Blaschke, 2010). La clasificación orientada a objetos se basa en la identificación de objetos definidos como grupos de píxeles contiguos que poseen un comportamiento similar, de manera que la variabilidad entre los píxeles que lo componen es inferior a la variabilidad entre el objeto y su entorno (Perea *et al.*, 2009).

En este trabajo se desarrolló una metodología para identificar cinco cultivos agrícolas combinando los sistemas de información geográfica (SIG) con percepción remota y las aplicaciones que brinda una hoja de cálculo.

La identificación se logró usando clasificación orientada a objetos, ya que hacen mejor uso de la información espacial implícita dentro de la imagen, (Blaschke *et al.*, 2014), donde cada objeto correspondió a una parcela de uno de los cinco cultivos analizados. Se adquirieron ocho imágenes RapidEye de distintas fechas para cubrir el ciclo agrícola, estas imágenes fueron corregidas radiométricamente para obtener la reflectancia en la superficie. Esta información fue trasladada al vector de parcelas y analizada tabular y gráficamente en una hoja de cálculo.

2. OBJETIVOS

2.1. General

Realizar una clasificación supervisada de cultivos agrícolas usando imágenes de satélite RapidEye en el Distrito de Riego 017, “Región Lagunera”.

2.2. Particulares

Obtener las firmas espectrales de los cultivos agrícolas de mayor importancia en el Distrito de Riego 017 “Región Lagunera” usando imágenes multiespectrales y multitemporales.

Determinar las longitudes de onda (bandas espectrales) que más diferencian a los cultivos agrícolas de mayor importancia en el Distrito de Riego 017 “Región Lagunera”.

3. REVISION DE LITERATURA

3.1. Sistemas de información geográfica (SIG)

Burrough y McDonnell (1998) definen a los Sistemas de Información Geográfica (SIG) como un sistema informático que facilita las fases de introducción de datos, gestión de datos, análisis de datos y presentación de datos específicamente para trabajar con datos georreferenciados. En el sentido amplio, un SIG requiere para funcionar tanto de hardware como de software, y también personas como los creadores o administradores de bases de datos, analistas que trabajan con el software, y los usuarios del producto final.

Los SIG se pueden utilizar en conjunto con otras herramientas como la percepción remota con el fin de utilizar la información espectral de forma integrada (Blaschke, 2010), además constituyen una tecnología con base digital orientada a proporcionar respuestas organizadas a distintos problemas que se representan en la integración y manejo de variables geográficas, cuantitativas y cualitativas que finalmente representan de manera gráfica los fenómenos y hechos físicos y sociales.

Un SIG es un sistema basado en una computadora que proporciona los siguientes cuatro grupos de capacidades para manejar datos georreferenciados (Burrough y McDonnell, 1998):

- a) Captura y preparación de datos
- b) La gestión de datos, incluidos el almacenamiento y mantenimiento
- c) La manipulación y análisis de datos
- d) Presentación de los datos

Esto implica, que un usuario SIG puede esperar el apoyo del sistema para introducir datos (georreferenciados), para analizarlos de diversas maneras, y generar

presentaciones (incluyendo mapas y otros tipos) de los datos. Esto podría incluir soporte para varios tipos de sistemas de coordenadas y transformaciones entre ellos, opciones para el análisis de los datos georreferenciados, y, obviamente, un alto grado de libertad de elección en la manera de presentar esta información (Burrough y McDonnell. 1998)

3.1.1. Algunos productos SIG en el mercado

Muchos son los softwares de SIG existentes en el mercado que permiten realizar análisis de datos alfanuméricos asociados con un componente espacial y/o realizar operaciones sobre imágenes existentes, los cuales facilitan la toma de decisiones.

ArcGis

El último producto comercializado por la empresa ESRI (Environmental Systems Research Institute) es ArcGIS. Este nombre se usa tanto para designar al conjunto de aplicaciones SIG de esta empresa (ArcGIS System) como a parte de sus productos (ArcGIS Desktop). ArcGIS nace en 2001 con la versión 8.1, como evolución natural de ArcView y, opcionalmente, incorporando Arc/Info con el apellido de Workstation (Mancebo *et al.*, 2008).

Erdas imagine

La compañía *Intergraph* describe a Erdas imagine como uno de los sistemas de creación de datos geoespaciales más importantes del mundo. Erdas incorpora un procesamiento geoespacial y análisis de imágenes, sensores remotos y capacidades de los SIG en un solo paquete de gran alcance, permitiendo a los usuarios crear fácilmente productos de valor agregado, tales como imágenes en 2D y 3D y composiciones de mapas con calidad cartográfica de datos geoespaciales. ERDAS IMAGINE proporciona herramientas para el procesamiento paralelo de

lotes, modelos espaciales, producción de mapas, mosaicos, y detección de cambios.

3.2. Percepción Remota o teledetección

Una de las más importantes fuentes de datos aplicadas a los Sistemas de Información Geográfica (SIG), es indudablemente aquella provista por la percepción remota. Mediante el uso de satélites, se tiene un continuo programa de adquisición de datos del mundo entero en tiempos que varían desde semanas hasta algunas horas. El acceso a las imágenes adquiridas a través de los sensores remotos en forma digital, permite una rápida integración de los resultados de su análisis directamente a los SIG (Bosque, 1994).

La percepción remota (*Remote Sensing*) o teledetección puede definirse como la ciencia y arte ciencia o tecnología de obtener información de un objeto analizando los datos adquiridos mediante algún dispositivo que no está en contacto físico con dicho objeto (Jensen, 2000), esto es posible gracias a la relación sensor-cobertura, la cual en el caso de los barredores multiespectrales se expresa a través de la llamada radiación electromagnética (Martínez, 2005). Estas radiaciones electromagnéticas pueden ordenarse en un espectro que se extiende desde ondas de frecuencias muy elevadas con longitudes de onda pequeñas como son rayos gamma, rayos X, radiación ultravioleta hasta frecuencias muy bajas con longitudes de onda grandes dentro de estas se encuentran luz visible, rayos infrarrojos, microondas y ondas de radio (Vázquez, 2008).

La teledetección, tal y como se entiende en la actualidad, comenzó en el periodo de 1946 a 1950, cuando se lanzaron desde Nuevo México (EE.UU.) los primeros cohetes V-2 con pequeñas cámaras fotográficas instaladas en ellos como sensores remotos (Labrador *et al.*, 2012).

La superficie terrestre se puede interpretar con diferentes técnicas de procesamiento aplicadas a la percepción remota, con determinado nivel de detalle. Estas técnicas y métodos permiten obtener información con cierto grado de confiabilidad y certidumbre de la actividad fotosintética que presentan las coberturas vegetales en un determinado momento (Chuvienco, 2002).

De acuerdo con Labrador *et al.*, (2012) la teledetección más utilizada se refiere a la captura de imágenes desde satélites o plataformas aéreas (aviones, helicópteros o vehículos aéreos no tripulados). Sin embargo, las ventajas que ofrece la observación espacial desde satélites, esto es, la cobertura global y exhaustiva de la superficie terrestre, la observación multiescala y no destructiva y la cobertura repetitiva, han propiciado el desarrollo y utilización de éste tipo de productos de manera sistemática.

La Teledetección presenta cualidades muy notables; entre ellas se pueden citar las siguientes:

1. Permite la adquisición de datos relativos al medio ambiente con una gran rapidez, poniendo a disposición de los investigadores un gran volumen de información que es susceptible de ser almacenada y analizada con posterioridad.
2. Da una visión sinóptica de los fenómenos naturales, y en el caso de la Teledetección espacial, su visión global de la cubierta terrestre pone de manifiesto las interacciones que existen entre los distintos fenómenos o sectores de actividad.
3. La repetición de las observaciones permite dar un contenido dinámico a los estudios, y seguir la evolución de la ocupación del espacio y de los fenómenos que allí se operan, pues las informaciones están perfectamente localizadas y por tanto se pueden comparar en el tiempo.

4. Tiene un costo menor que los sistemas de información convencionales en zonas de la tierra de poca accesibilidad y gran extensión, como suele ocurrir en los países en vías de desarrollo.

3.2.1. Satélites

La mayor parte de los satélites de teledetección se diseñan para seguir una órbita de norte a sur, la cual, en conjunción con la rotación de la Tierra (de oeste a este), les permite cubrir la mayor parte de la superficie terrestre durante un cierto periodo de tiempo. A estas órbitas se les ha dado el nombre de cuasi polares, por la inclinación relativa con respecto a una línea trazada entre los polos norte y sur. Además, muchos de los satélites de órbita cuasi polar también son heliosíncronos, ya que cubren la misma área del mundo a una hora local fija del día, llamada hora solar local. Esto significa que, a una latitud dada, la posición del Sol en el cielo, al igual que la posición del satélite que pasa por encima, será aproximadamente la misma dentro de la misma estación del año. Este hecho asegura condiciones de iluminación similares cuando se adquieren imágenes en una estación específica durante diferentes años, o en un área particular sobre una serie de días (Labrador *et. al.*, 2012).

En el movimiento alrededor de la Tierra, el satélite sólo registra información de una porción de la misma. El ancho de la franja en la superficie terrestre que es capaz de registrar se denomina ancho de barrido. Este puede variar desde decenas a cientos de kilómetros, dependiendo del tipo de sensor y de la altura del satélite. Esta característica determinará en muchos satélites la capacidad para captar, en una sola pasada, un área determinada. Varios satélites modernos tienen la capacidad de reorientar en cualquier dirección (off-nadir) el sensor durante la adquisición de imágenes y tomar franjas adyacentes en una única pasada. Este hecho se traduce en un aumento del ancho de barrido práctico del satélite, lo cual supone un

incremento importante en la capacidad de adquisición de imágenes de los satélites que poseen esta tecnología (Labrador *et. al.*, 2012).

3.2.2. Sensores

Los sensores son instrumentos susceptibles de detectar la señal electromagnética (radiación reflejada o emitida) que les llega de la Tierra y la atmósfera y convertirla en una magnitud física que pueda ser tratada y grabada. Los sensores convierten la señal electromagnética en un formato analógico (fotografía) o digital (imagen). Para llevar a cabo la observación del terreno, los sensores se ubican en plataformas, fijas o móviles (Sobrino, 2011).

Sobrino agrupa a los sensores en dos grupos, de acuerdo al origen de la señal captada:

Métodos pasivos: Se basan en la detección de las características reflectantes del sistema observativo, es decir, el sensor cumple la misión de registrar la radiación emitida por el sistema observado o la radiación solar reflejada. Ej. Cámara fotográfica.

Métodos activos: El sensor cumple una doble función ya que actúa activamente produciendo una señal (onda electromagnética) de características conocidas. La información obtenida procede de la comparación entre la señal emitida y la señal reflejada. Ej. Radar.

De acuerdo a espectro electromagnético, Sobrino (2011) agrupa los sensores en tres categorías: técnicas en el visible infrarrojo próximo, técnicas de infrarrojo térmico y técnicas en las microondas. Y finalmente de acuerdo a la forma en que registran la señal, los agrupa en dos familias: los que permiten una adquisición casi instantánea del conjunto de la escena observada y los sensores que ofrecen una

adquisición secuencial de elementos de la imagen con los cuales, dato a dato se constituye el conjunto de escena.

Cualidades de los sensores

Puede definirse la resolución de un sensor como su habilidad para registrar y discriminar información de detalles lo que depende del efecto combinado de sus distintos componentes. La resolución de un sensor implica considerar la calidad de la información aportada en distintos aspectos (Sobrino, 2001), por lo que en la práctica se habla de cuatro tipos de resolución: espacial, espectral, radiométrica y temporal.

Resolución temporal

La resolución temporal es el ciclo de repetición, o intervalo de tiempo, entre dos adquisiciones de imágenes sucesivas de una misma porción de la superficie y depende, en gran medida, de las características orbitales del satélite. Muchas veces también se la denomina periodo de revisita (Labrador *et al.* 2012). La resolución temporal alude a la frecuencia de cobertura que proporciona el sensor, esto es, la periodicidad con que adquiere imágenes de la misma porción de la superficie terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma (altura, velocidad, inclinación) así como el diseño del sensor (ángulo de observación y abertura) (Sobrino, 2001).

Resolución Espectral

Labrador *et al.* (2012) definen la resolución espectral de un sensor como el número y anchura de las bandas espectrales que puede discriminar.

Entre los sensores espaciales, la menor resolución espectral corresponde al radar y a los sistemas fotográficos; por el contrario los sensores óptico-electrónicos

ofrecen un amplio rango de bandas. La elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionada con los objetivos de su diseño (Martínez, 2005).

Resolución Radiométrica

Se refiere a la capacidad para detectar variaciones en la radianza espectral que recibe. En el caso de los sistemas óptico-electrónicos, la imagen habitualmente se presenta en formato digital, gracias a una conversión analógico-digital realizada a bordo del satélite. El número de valores que incluye ese rango, es decir, el número máximo de niveles digitales de la imagen, suele identificarse con la resolución radiométrica del sensor (Martínez, 2005).

Resolución espacial

Se refiere al objeto más pequeño que puede ser distinguido sobre la imagen de satélite. El objeto, es la mínima separación a la cual los objetos aparecen distintos y separados en la fotografía. Se mide en unidades de longitud (metros sobre el terreno), y depende de la longitud focal de la cámara y de su altura sobre la superficie. Esa distancia corresponde al tamaño de la mínima unidad de información incluida en la imagen, que se denomina píxel; esta es la medida más generalizada de la resolución espacial. La resolución espacial está en estrecha relación con la escala de trabajo y con la fiabilidad finalmente obtenida en la interpretación (Martínez, 2005).

3.2.3. Imágenes de satélite

Una imagen satelital es una representación visual de la información capturada por un sensor montado en un satélite artificial. La imagen satelital es la representación de la realidad en forma de una matriz de datos, donde cada celda o píxel es una porción del área observada con un único valor.

Las imágenes satelitales almacenan por lo general las variaciones de la intensidad de energía reflejada por la superficie y registrada por el sensor. Estos valores se conocen como **Niveles Digitales (ND)** para cada píxel y normalmente oscilan entre 0 a 255 (8 bits) y 0 a 65,535 (16 bits). El nivel digital correspondiente a un píxel será, de este modo, proporcional a la intensidad de radiancia procedente del terreno (Pérez y Muñoz, 2006).

Las imágenes satelitales ofrecen información valiosa para innumerables aplicaciones: planificación urbana, vigilancia del medio ambiente, gestión de cultivos, exploración minera, desarrollo de mercados, localización de bienes raíces, entre otros. En forma adicional a la información que se puede observar a través del ojo humano, las imágenes contienen detalles “ocultos” es así que en la información espacial registrada por las imágenes, se puede observar el contenido mineral de las rocas, la humedad del suelo, la salud de la vegetación, la composición física de los edificios y otros detalles imperceptibles por el ojo humano, esta información se logra por la reflectancia o el denominado contenido espectral de la imagen satelital.

Las imágenes obtenidas por los satélites ofrecen una perspectiva única de la Tierra, sus recursos y el impacto que sobre ella ejercen los seres humanos. La teledetección por satélite ha demostrado ser una fuente rentable de valiosa información para numerosas aplicaciones, entre las que cabe citar la planificación urbana, vigilancia del medio ambiente, gestión de cultivos, prospección petrolífera, exploración minera, desarrollo de mercados, localización de bienes raíces y muchas otras.

El valor de las imágenes de satélite y la información extraída de ellas son evidentes. Ofrecen una visión global de objetos y detalles de la superficie terrestre y facilitan la comprensión de las relaciones entre ellos que pueden no verse claramente cuando se observan a nivel de tierra. Además, las imágenes de satélite muestran literalmente, mucho más de lo que el ojo humano puede observar, al desvelar

detalles ocultos que de otra forma estarían fuera de su alcance. Algunas imágenes, por ejemplo, muestran las enfermedades de la vegetación, la existencia de minerales en afloramientos rocosos o la contaminación de los ríos. Las imágenes obtenidas a partir de plataformas espaciales constituyen una fuente muy importante de información sobre los recursos naturales y del ambiente.

3.3. Espectro Electromagnético

En teledetección, las ondas se clasifican por su longitud. El agrupamiento del conjunto de ondas que se encuentran en la naturaleza con respecto a sus longitudes forma lo que se llama el “espectro electromagnético” (Figura 1) (Manual de teledetección, 2004)

El visible (VIS) es una pequeña región del espectro electromagnético que apenas abarca desde los 0.4 μm hasta los 0.7 μm . El color azul va desde 0.4 hasta 0.5 μm , el verde desde 0.5 μm hasta 0.6 μm y el rojo de 0.6 μm a 0.7 μm . La energía ultravioleta (UV) se encuentra inmediatamente por debajo del color azul. Por encima del rojo se sitúa la región infrarroja (IR), que a su vez está dividida en tres categorías: IR próximo (NIR) (0.7 – 1.3 μm), IR medio (SWIR) (1.3 – 3 μm) e IR térmico (TIR) (3 – 100 μm). La porción de microondas se encuentra más allá del IR, a longitudes de onda mucho más grandes (1 mm – 1 m), que son las longitudes de onda más largas usadas en teledetección. De éstas, las más cortas tienen propiedades similares al IR térmico, mientras que las restantes son similares a las usadas en comunicaciones (Labrador *et al.*, 2012).

3.3.1 Rangos del espectro electromagnético.

Martínez y Díaz, (2005) describen los siguientes rangos dentro del espectro electromagnético:

- Espectro visible (0.4 a 0.7 μm). Es la única radiación electromagnética que puede percibir el ojo humano.
- Infrarrojo cercano (0.7 a 1.3 μm). Es de especial importancia, puesto que puede detectarse a partir de films dotados de emulsiones especiales.
- Infrarrojo medio (1.3 a 8.0 μm). Se entremezclan los procesos de reflexión de la luz solar y de emisión de superficie terrestre.
- Infrarrojo lejano o térmico (0.8 a 14 μm). Influye la porción emisiva del espectro terrestre.
- Microondas (a partir de 1mm). Energía bastante transparente a la cubierta nubosa.

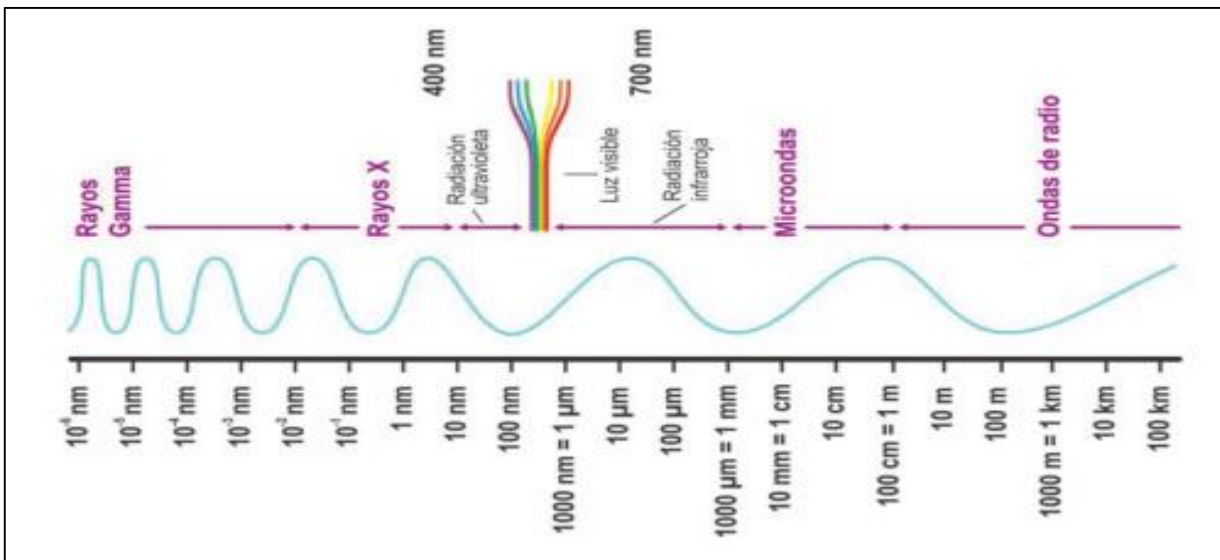


Figura 1. Espectro electromagnético

Fuente: Satélites de teledetección para la gestión de territorio.

3.3.2 Firmas espectrales

Los satélites miden la energía reflejada o emitida por los objetos de la superficie terrestre, según el poder de reflectividad y emisividad de cada uno, y también según la longitud de onda. Así, como los objetos reaccionan en forma diferente ante la energía solar recibida, cada objeto posee una reflectividad propia llamada “firma

espectral”. Es el conocimiento de la reflectividad de cada objeto lo que hace posible su identificación a partir de las imágenes (Manual de teledetección, 2004).

El conocimiento de las firmas espectrales es fundamental en teledetección, no sólo para identificar los distintos objetos sino para elegir las bandas más apropiadas y el sensor más conveniente. La Figura 2 presenta las firmas espectrales de las tres coberturas principales de la superficie terrestre: vegetación, suelo y agua. Las mejores bandas para discriminar las tres coberturas son, en orden de importancia, el Infrarrojo Cercano, el Infrarrojo Medio y el Rojo. Ello se debe a que existen grandes diferencias en la reflectividad de los tres elementos, lo que asegura su discriminación. En cuanto a las otras bandas, la diferencia no es muy significativa, lo que reduce considerablemente el potencial discriminatorio de éstas.

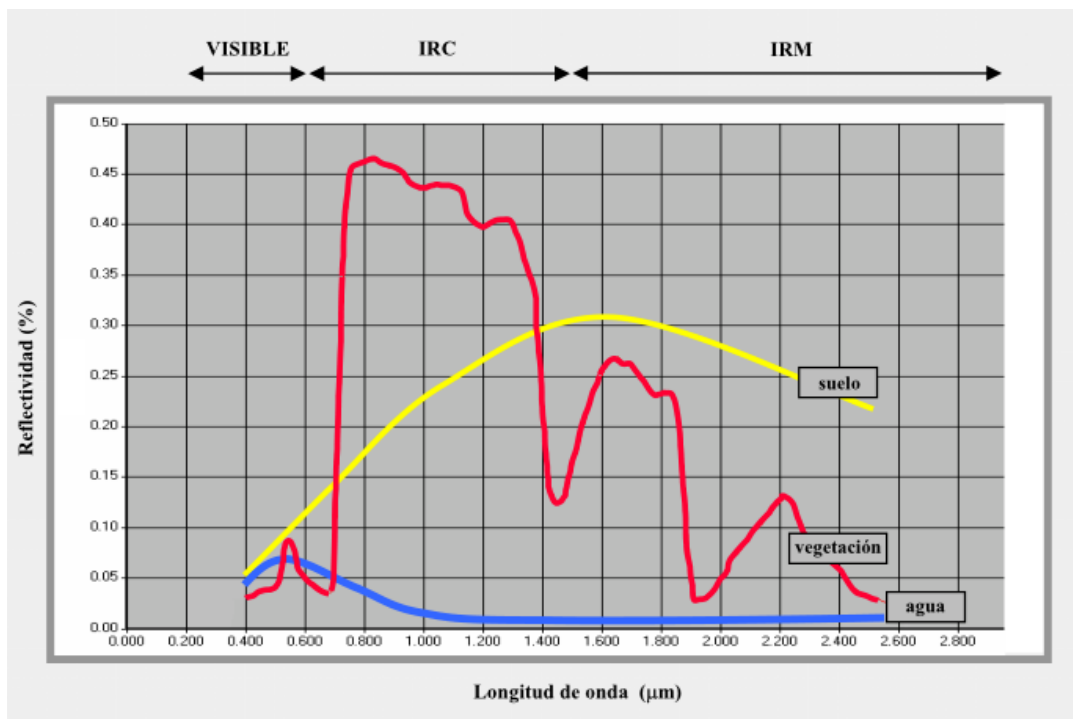


Figura 2. Firmas espectrales típicas de la vegetación, agua y suelo

Fuente: Manual de teledetección, 2004

3.4. Clasificación de imágenes

La mayoría de las técnicas usadas para la extracción de información son clasificaciones basadas en parámetros estadísticos deducidos de zonas de la imagen estudiada. La clasificación de acuerdo con el proceso de construcción se ha dividido en dos grupos: supervisada y no supervisada, pudiéndose utilizar estos tipos de clasificaciones tanto para clasificación por píxeles como para clasificación por objetos (Vicente, 2011). El método supervisado parte de un conocimiento previo del terreno del cual se seleccionan las muestras para cada una de las diferentes categorías. En cambio, en el método no supervisado se buscan automáticamente grupos de valores espectrales homogéneos en la imagen aplicando estrategias que aprovechen las características espectrales de la imagen, que no requieran del etiquetado previo de los patrones para que después el usuario intente encontrar las correspondencias entre esos grupos seleccionados automáticamente y las categorías que le puedan ser de interés (Macedo, 2012).

La selección de las variables adecuadas es un paso fundamental para la implementación exitosa de una clasificación de imágenes. Debido a las diferentes capacidades en la separación de la cubierta terrestre, el uso de demasiadas variables en un proceso de clasificación puede disminuir la precisión, por lo que es importante seleccionar sólo las variables que son más útiles para la separación de clases de uso del suelo o vegetación, sobre todo cuando se usan datos hiperespectrales o fuentes múltiples (Lu y Weng, 2007).

Los criterios más comunes para establecer fronteras estadísticas entre clases son (Vásquez, 2008):

Mínima distancia: donde el pixel se le asigna el valor de cada clase más cercana; esto es en aquella que minimice la distancia entre este pixel y el centroide de la clase. Debe tenerse claridad en que no se trata de distancias geográficas sino de

distancias espectrales, consecuencia de comparar los niveles digitales de cada pixel.

Paralelepipedos: Agrupan las clases en los rangos mínimos y máximos de acuerdo al tipo de clasificación; se fija en un área de dominio para cada categoría, teniendo en cuenta sus valores de centricidad y dispersión. Un pixel es asignado a dicha clase si sus niveles digitales están dentro de esa área de dominio en las bandas consideradas.

Máxima probabilidad: Es cuando el pixel se asigna a la clase con que posee mayor probabilidad de pertenencia. Este método considera que los niveles digitales en el seno de cada clase se ajustan a una distribución normal. Esta particularidad permite describir esa categoría por función de probabilidad, a partir de su vector y matriz de varianza-covarianza (Lillesand *et al.*, 2004). El cálculo se realiza para todas las categorías que intervienen en la clasificación, asignando el pixel a aquella que maximice la función de probabilidad.

A pesar de que el clasificador de máxima probabilidad es el más complejo y el que demanda mayor volumen de cálculo, es el más empleado por ajustarse con más rigor a la disposición de original de datos (Vázquez, 2008).

3.4.1 Método supervisado.

Este método de clasificación requiere un cierto conocimiento de la zona de estudio que permite delimitar sobre la imagen zonas o áreas representativas de las distintas categorías que se pretenden discriminar. Estas áreas se conocen como *training fields* (áreas de entrenamiento) ya que sirven para que se pueda reconocer las distintas categorías. A partir de estas áreas la computadora calcula diversos parámetros estadísticos de los ND que definen cada clase, para luego clasificar el resto de píxeles en una categoría determinada atendiendo a sus ND. Resulta

adecuado seleccionar varias áreas de entrenamiento por clase para reflejar correctamente su variabilidad en la zona de estudio.

Una vez terminada la selección de las áreas de entrenamiento, se procede a calcular las estadísticas elementales de cada categoría: media, rango, desviación típica, matriz de varianza – covarianza, etc., a partir de los ND de todos los píxeles incluidos en el área de entrenamiento de dicha clase. Este cálculo es aplicado a cada banda espectral. Las medidas extraídas a partir de los ND de cada área de entrenamiento definen a cada clase, por lo tanto es muy importante su correcta selección ya que de otro modo se forzaría a clasificar áreas heterogéneas.

3.4.2 Método no supervisado

Aragon *et al.*, (2005) mencionan que la aplicación de esta clasificación opera como una búsqueda automática de grupos de valores homogéneos dentro de las imágenes, pero pueden ocurrir varias posibilidades: que una categoría esté expresada en varias clases espectrales, que dos o más categorías compartan una sola clase espectral, que varias categorías compartan clases espectrales y la ideal, que haya una correspondencia biunívoca entre las clases espectrales y las categorías.

Este método de clasificación trata de definir las clases espectrales presentes en la imagen. No implica ningún conocimiento previo del área de estudio por lo que la intervención humana se centra en la interpretación de los resultados.

Un método dentro de éste tipo de clasificación es el de Otsu que de acuerdo con la investigación realizada por Macedo *et al.*, (2010), permitió obtener el valor de umbral óptimo como base para segmentar y clasificar imágenes en modelo a color, mediante el método de clasificación no supervisada.

Este método asume que los ND de la imagen se agrupan en una serie de conglomerados (o clusters) que se corresponden con grupos de píxeles con un comportamiento espectral homogéneo y que, por ello, deberían definir unas clases informacionales de interés. Por desgracia estas clases espectrales no pueden ser asimiladas siempre a las categorías temáticas que el usuario pretende deducir por lo que es labor de éste interpretar el significado temático de dichas categorías espectrales.

3.5. Corrección y transformación de imágenes

Chuvieco, (1990) indica que la corrección de imágenes consiste en aquellos procesos que tienden a eliminar cualquier anomalía detectada en la imagen, ya sea en su localización y en los ND de los píxeles que la componen. Por corrección se entiende solventar algún defecto en la adquisición, emisión o recepción de la imagen, para disponerla más adecuadamente para su interpretación. Es necesario corregir la imagen si sus datos fueron adquiridos en condiciones de observación perfecta e invariante (Peña, 2007).

Peña, (2007) señala que las imágenes requieren una serie de procedimientos de corrección, en especial si se desea estimar alguna propiedad con un sentido físico preciso, como es el caso de la fracción de cobertura vegetal (VCF, vegetation cover fraction), o relacionar cuantitativamente una estimación con la fisiología de la vegetación, como ocurre con el índice de vegetación de diferencia normalizada (NDVI, normalized difference vegetation index).

Como lo mencionan Lu y Weng (2007), el Pre-tratamiento de la imagen incluye la detección y la restauración de malas líneas, la rectificación geométrica o registro de la imagen, la calibración radiométrica y corrección atmósfera-esférica, así como la corrección topográfica. Si se utilizan diferentes datos auxiliares, la conversión de datos entre diferentes fuentes o formatos y evaluación de la calidad de estos datos

también son necesarios antes de que puedan ser incorporados en un procedimiento de clasificación. La rectificación geométrica exacta o el registro de imágenes de datos de sensores remotos es un requisito previo para una combinación de diferentes datos de origen en un proceso de clasificación.

Dentro de las correcciones encontradas en la literatura, se encuentran las siguientes:

3.5.1 Corrección del bandeo de la imagen

Eastman, (2006) define como “destriping” al procedimiento que corrige los valores erróneos de las líneas de exploración. Se trata del cálculo de la media (o mediana) y la desviación estándar para toda la imagen y después para cada detector por separado. Algunos paquetes de software ofrecen una opción para aplicar una máscara a la imagen para excluir ciertas áreas de estos cálculos (por ejemplo, las nubes y las sombras de éstas deben ser excluidos). En ocasiones, sólo una parte de la imagen (por lo general un área homogénea, tal como un cuerpo de agua) se utiliza para estos cálculos.

3.5.2 Correcciones radiométricas

Técnicas que modifican los ND, con objeto de acercarlos a los que habría presentes en la imagen caso de una recepción ideal. Dentro de este concepto se engloban las distorsiones provocadas por la atmósfera, así como los problemas radiométricos (Chuvieco, 1990).

Modelo de reflectancia aparente

De acuerdo con Chuvieco y Hantson, (2010) para poder utilizar la información radiométrica de la imagen en todas las facetas es necesario convertir la reflectividad

en el techo de la atmosfera (TOA) a reflectividad de la superficie terrestre. La señal recibida por los sensores se codifica en los diferentes valores de ND de acuerdo a la reflexión de la radiación electromagnética de las cubiertas. El proceso inverso, conversión de los ND a reflectividades, se realiza en dos fases: primero pasar ND a valores de radiancia, a partir de los coeficientes de calibración, y luego estimar los valores de reflectividad aparente, conociendo la irradiancia solar y la fecha de adquisición de la imagen (Brizuela *et al.*, 2007).

El algoritmo de corrección atmosférica corrige la señal recibida por el sensor de la influencia y distorsiones radiométricas causadas por la atmósfera. Aunque el algoritmo es un modelo sencillo, presenta los mejores resultados considerando la estabilidad temporal de zonas pseudo-invariantes. El modelo toma en cuenta la trasmisividad de la atmósfera en el camino sol-tierra y la dispersión atmosférica pero ignora la irradiación difusa y la trasmisividad de la atmósfera en el camino tierra-sensor (Chuvieco y Hantson, 2010).

3.5.3 Restauración de líneas o pixeles perdidos

Chuvieco (1990) menciona que los procesos de corrección se dirigen a mejorar artificialmente el aspecto visual de la imagen, para facilitar su posterior interpretación, ya que se trata de información irreparablemente perdida.

3.5.4 Corrección atmosférica

La energía radiada por la superficie terrestre debe recorrer una cierta distancia a través de la atmósfera antes de ser detectada por un sensor, la cual es conocida como longitud de ruta (*path length*). Durante este viaje, el flujo radiante es esparcido y absorbido por los aerosoles atmosféricos, lo que modifica la radiancia que finalmente registran los detectores del sensor desde su objetivo. Este efecto puede ser minimizado mediante la aplicación de un modelo de corrección atmosférica sobre las bandas de la imagen (Peña, 2007).

Dentro de los modelos para efectuar correcciones atmosféricas, encontramos algunos utilizados por Brizuela *et al.*, (2007),: modelo de reflectancia aparente (AR), sustracción del objeto oscuro (DOS) y el modelo COST que constituye una mejora del anterior pues incorpora una estimación de la transmitancia. Dichos modelos estiman el efecto atmosférico y corrigen parcialmente los datos de acuerdo a la posición del sol y la transmitancia. El modelo COST aplica la sustracción del objeto oscuro para el efecto de bruma e incorpora una estimación de la transmitancia ya que ésta representa la absorción por parte de los gases atmosféricos y de la dispersión Rayleigh.

Modelo de Sustracción de Objetos Oscuros

El modelo de Sustracción de objeto oscuro propuesto por Chávez (1988) ha sido utilizado en numerosas aplicaciones probablemente por ser de aplicación simple. Postula que la bruma atmosférica incrementa los ND en áreas de las imágenes de agua limpia, profunda y calma, donde por las características físicas deben presentar reflectancia nula. El valor representativo de esa diferencia se sustrae, en cada banda, en todos los píxeles de la escena (Brizuela *et al.*, 2007).

El modelo de sustracción de objetos oscuros asume los siguientes puntos (Brizuela *et al.*, 2007):

- Un valor representativo ND, mayor a cero, en áreas de agua limpia, profunda y calma representa el aporte de la bruma y por lo tanto se puede sustraer en cada banda (restar a toda la imagen el mínimo valor encontrado).
- Compensa las variaciones en la radiación solar según el momento del año y el ángulo de elevación del sol.

- Requiere estimar el ND que corresponde al objeto oscuro, fecha y hora de toma de la imagen, longitud de onda central de cada banda, elevación solar y coeficientes de conversión de la radiancia

3.5.5 Corrección geométrica

Este concepto incluye cualquier cambio en la posición que ocupan los píxeles de la imagen. Por contraposición con las correcciones radiométricas, aquí no se pretende modificar los ND de los píxeles de la imagen, sino solo su posición, es decir sus coordenadas. Por tratarse de un formato digital, esta transformación puede basarse en funciones numéricas, que permiten modificar muy flexiblemente la geometría de la imagen (Chuvienco, 1990). La mayoría de los elementos de la restauración geométrica asociados a la captura de imágenes son corregidos por los distribuidores de la imagen, principalmente la corrección de la inclinación y la distorsión del escáner (Eastman, 2006).

De acuerdo con Eastman, (2006) la georreferenciación no es sólo una técnica de restauración, sino un método de reorientación de los datos para satisfacer objetivos específicos y requisitos del proyecto del usuario. Como tal, es particularmente importante que la imagen georeferenciada cumpla con los estándares del usuario y sea registrada adecuadamente con otros datos en la misma proyección y el sistema de referencia.

El Manual de Teledetección, (2004) establece que existen dos métodos para corregir la geometría de las imágenes. El primero utiliza modelos matemáticos basados en el conocimiento preciso de los parámetros al momento de la toma de datos. Este método, también denominado “corrección orbital”, pretende modelar aquellas fuentes de errores geométricos conocidos, y para ello necesita disponer de las características orbitales de la plataforma. Este tipo de corrección es generalmente realizado por las empresas proveedoras de imágenes satelitales, tal como la CONAE (Comisión Nacional de Actividades Espaciales), quienes aplican

estas correcciones antes de entregar las imágenes a los usuarios. El segundo, conceptualmente más simple y por ese motivo de uso más generalizado, trata de modelar el error geométrico de la imagen a partir de una serie de puntos de control. La ventaja de este método es que no requiere conocimiento *a priori* de las relaciones complejas del sistema de adquisición, las relaciones con el terreno, la plataforma y el sensor.

3.6. Unidades de Muestreo

Las unidades de muestreo son partes del mapa que serán seleccionadas para la evaluación de la exactitud. De acuerdo con Congalton (2009), hay cuatro opciones posibles para la unidad de muestreo: (1) un solo píxel, (2) un grupo de píxeles (a menudo un cuadrado de 3 × 3 píxeles), (3) un polígono (o un objeto), y (4) un grupo de polígonos.

3.6.1 Un solo píxel

Históricamente, un gran número de evaluaciones de precisión se han llevado a cabo usando un solo píxel como la unidad de muestreo. Los clasificadores tradicionales por píxel pueden conducir al llamado efecto de "sal y pimienta" en los mapas de clasificación, generalmente se aplica un filtro a para reducir éste tipo de ruidos (Lu y Weng, 2007). Sin embargo, un solo píxel es una opción muy pobre para evaluar una unidad de muestreo debido a varias razones:

- En primer lugar, un píxel es un trazo rectangular arbitrario del paisaje que puede tener poca relación con el trazado actual de la cubierta vegetal o tipo de uso de la tierra. Puede ser una cubierta vegetal única o una categoría de vegetación o frecuentemente, puede ser una mezcla de la cubierta vegetal o las clases de vegetación.
- En segundo lugar, antes de que nuevas geocodificaciones y procedimientos de corrección del terreno fueran adoptados, era casi imposible alinear

exactamente un píxel en el mapa a la misma área de los datos de referencia. Por lo tanto, no había manera de garantizar que la ubicación del píxel de referencia fuera idéntica a la ubicación del píxel del mapa. Incluso con la corrección de terreno y georreferenciación, no es posible obtener una alineación exacta de los límites de un píxel. Del mismo modo, hasta que el sistema de posicionamiento global (GPS) llegó, no había una manera práctica de asegurar que los datos de referencia estaban siendo colectados para el píxel exacto del mapa que se estaba evaluando. Incluso con el GPS, esta correspondencia no está garantizada para que coincida exactamente. Por lo tanto, la exactitud posicional se convierte en un gran problema, y la exactitud temática del mapa es afectada debido al error posicional.

- Finalmente, pocos esquemas de clasificación especifican una unidad tan pequeña como un píxel como la unidad mínima de mapeo. Si la unidad mínima de mapeo es más grande que un solo píxel, un único píxel no es apropiado como unidad de muestra.

Incluso con todos los últimos avances tecnológicos en el GPS, la corrección del terreno y la codificación geográfica, la evaluación de la exactitud de unidades de muestra seguirá teniendo algunas inexactitudes posicionales.

Se acepta comúnmente que la precisión posicional de un medio píxel es suficiente para sensores como Landsat, Thematic Mapper, e imágenes multiespectrales SPOT. A medida que aumenta la resolución espacial de los sensores, como la obtenida de cámaras digitales aéreas y satélites de alta resolución, la precisión posicional se vuelve más importante y es necesario establecer nuevos estándares. Si una imagen con un tamaño de píxel de 10-30 m es registrado en suelo dentro de la mitad de un píxel (es decir, 5-15 m) y una unidad de GPS es usada para localizar la unidad dentro de 10-15 m, entonces es imposible utilizar un solo píxel como la unidad de muestreo para evaluar la exactitud temática del mapa. Podría no haber ninguna garantía de que el mapa y los datos de referencia se hayan obtenido de un área idéntica (Congalton, 2009).

Si la precisión de la posición no es hasta el nivel o si el GPS no es usado para localizar con precisión la muestra en suelo se puede afectar significativamente la evaluación de la exactitud temática. Esto es aún más representativo para las imágenes de mayor resolución espacial, en las que los píxeles pueden ser más pequeños.

3.6.2 Grupo de Píxeles

Debido a la necesidad de equilibrar la exactitud temática con la exactitud posicional, un grupo de píxeles, por lo general un cuadrado de 3×3 para imágenes de resolución moderada, ha sido recientemente la opción más común para la unidad de muestreo. Un grupo de píxeles minimiza los problemas de registro, ya que es más fácil de localizar en los datos de referencia o en el campo. Sin embargo, un grupo de píxeles (en especial de 3×3) aún puede ser una delimitación arbitraria del paisaje que resulta en una unidad de muestra que abarca más de una categoría. Para evitar éste problema, muchos analistas requieren que sólo los grupos homogéneos de píxeles sean muestreados. Sin embargo, tales restricciones pueden dar como resultado una muestra sesgada que evita zonas heterogéneas, las cuales son el resultado de una mezcla de píxeles (por ejemplo, una mezcla de madera dura con coníferas) como se muestra en la Figura 3 (Congalton, 2009).




Figura 3. Comparación de la exactitud de evaluación de polígonos (píxeles homogéneos y píxeles heterogéneos).

Fuente: Congalton and Green, 2009

Es importante recordar que la unidad de muestra determina el nivel de detalle de la evaluación de la precisión.

Si se lleva a cabo la evaluación de un grupo de píxeles de 3×3 , entonces nada se puede decir sobre un píxel individual. Además, cada unidad de la muestra debe ser considerada como una sola muestra. Si, por ejemplo, un grupo de 3×3 píxeles se utiliza como la unidad de muestra, entonces debe ser contado como una muestra, y no como nueve muestras. Hay numerosos ejemplos en la literatura de autores que erróneamente consideran cada píxel en grupo de píxeles como una unidad separada de evaluación. Además, la presencia de autocorrelación espacial en la mayoría de los mapas temáticos dicta que las muestras deben ser separadas adecuadamente una de otra (Congalton, 2009).

Extendiendo el concepto de grupo de píxeles para imágenes de mayor resolución se requiere el conocimiento acerca de la precisión posicional de las imágenes. La

precisión de registro común (de posición) para las imágenes satelitales de Landsat Thematic Mapper (30 m/píxel) y SPOT (10 m/píxel) son aproximadamente la mitad de un píxel. Por lo tanto, la selección de un grupo homogéneo de 3 x 3 píxeles asegura que el centro de la muestra sin duda está dentro del grupo de píxeles de 3x 3. Imágenes con resolución espacial mayor, como la de *Ikonos* o *Digital Globe* tienen un tamaño de píxel de 4m a 1 m. Sin embargo, la exactitud posicional de estos datos están a menudo en el intervalo de 10-20 m e incluso puede ser mucho más grande. Por lo que un grupo de 3 x 3 píxeles como unidad de muestreo no sería apropiado en este caso. Si la precisión de registro fue de 10 m y el tamaño de píxel fue de 4 m, el grupo de píxeles tendría que ser por lo menos de 5 x 5 píxeles para tener en cuenta este error posicional. Es indispensable que la exactitud posicional sea considerada en la selección del tamaño del grupo de píxeles de la unidad de muestra o de lo contrario la evaluación temática será imperfecta (Congalton, 2009).

3.6.3 Polígonos

Cada vez son más los proyectos de mapeo en teledetección que generan polígonos antes que grupos de píxeles debido al resultado del desarrollo de la segmentación de imágenes y el análisis basado en objetos. Como resultado, el polígono es la sustitución de elegir un grupo de píxeles como unidad de muestra.

La mayoría de los mapas temáticos de gran escala delimitan el paisaje en polígonos de clases homogéneas del mapa. Mientras que los píxeles dentro de los polígonos pueden variar drásticamente (como en un conjunto escaso de árboles), la etiqueta de clase a través de los píxeles es constante. Por lo general, el mapa de polígonos se crea ya sea a través de la interpretación manual o mediante el uso de segmentación de imágenes y algoritmos de clasificación orientados a objetos.

Si el mapa a ser evaluado es un mapa de polígonos, la evaluación de exactitud de las unidades de muestra debe ser también mediante polígonos. Los valores de

precisión resultantes informan al usuario y productor el nivel de detalle del mapa en el cual están interesados: los polígonos.

A pesar de varias ventajas que presenta el uso de polígonos como unidades de muestreo puede existir confusión en la evaluación de la exactitud cuando los polígonos son colectados durante la fase inicial de calibración de datos del trabajo de campo, antes de que sea creado el mapa de polígonos. El resultado a menudo puede ser delimitado manualmente por la exactitud de los polígonos con trazos considerablemente diferentes que los polígonos finales del mapa, como se ilustra en la Figura 4. Cuando esto ocurre se deben desarrollar algunas maneras de crear la etiqueta de mapa para el polígono de evaluación. El método más simple es utilizar la clase mayor del polígono para crear la etiqueta del mapa. Sin embargo, esto puede no ser adecuado en condiciones heterogéneas, donde la etiqueta está en función de la mezcla de la cubierta vegetal (por ejemplo, algas marinas o bosques de coníferas) en lugar de la mayor cubierta del suelo. Otro método consiste en ejecutar algoritmos de segmentación y concluir el trazado de los polígonos antes de iniciar la fase de campo. Los polígonos resultantes probablemente variarán muy poco de los polígonos finales y por lo tanto se pueden utilizar como unidades de muestreo de precisión confiable (Congalton, 2009).



Figura 4. Evaluación de exactitud del polígono de referencia de bosque mixto sobre bosque siempre verde, mixto y bosque caducifolio.

Fuente: Congalton and Green, 2009

3.7. Índices de vegetación

De acuerdo con Marín *et al.* (2011) los índices de vegetación permiten realizar una estimación de la abundancia de vegetación utilizando datos espectrales, basándose para ello en las diferencias espectrales dadas entre la vegetación y otros componentes de la superficie terrestre. Son indicadores del estado del desarrollo vegetativo de los cultivos o bien de las condiciones de uso de suelo. Salazar *et al.* (2007) definen al índice de vegetación (IV) como un parámetro calculado a partir de valores de reflectancia espectral a distintas longitudes de onda y que pretende extraer de los mismos la información relacionada con la vegetación minimizando la influencia de perturbaciones como las debidas al suelo y a las condiciones atmosféricas.

Los índices de vegetación basados en el espacio espectral tratan de calcular el estado de crecimiento de un cultivo (índice de área foliar u otra variable relacionada), sin embargo, para entender las limitaciones de los IV es necesario definir el contexto de lo que se caracterizará: un IV trata de aproximar una línea recta usando sólo un par de valores (R, IRC) que representan una cantidad desconocida de vegetación mezclada con un suelo de reflectividad también desconocida (Paz *et al.*, 2007).

Estos índices se obtienen mediante el contraste entre la reflectancia de diferentes bandas, o bien de su equivalente, la brillantez que se expresa como un número digital (Palacios, 2007). Están basados en combinaciones algebraicas de valores de reflectividad en las zonas espectrales del rojo (R) e infrarrojo cercano (IRC), puesto que es donde se produce un mayor contraste espectral entre la firma espectral del suelo y de la vegetación (Vercher *et al.*, 2002)

Jackson y Huete, (1991) dividen los índices de vegetación en dos clases: combinaciones y relaciones lineales, los primeros son grupos ortogonales de n ecuaciones lineales calculadas a partir de n bandas espectrales; mientras que las

relaciones lineales, son una simple proporción entre dos bandas (de sumas, restas o productos de algunas bandas. Vercher *et al.*, (2002), siguiendo el criterio de clasificación propuesto por Rondeaux et al. agrupan en tres categorías los índices de vegetación:

- 1) Índices intrínsecos que se basan en las medidas de reflectividad espectral sin considerar ningún otro parámetro externo: RVI (Pearson y Miller, 1972), NDVI (Rouse *et al.*, 1974).
- 2) índices que utilizan la línea de suelo: PVI (Jackson *et al.*, 1980), SAVI (Huete, 1988), TSAVI (Baret y Guyot, 1991), MSAVI (Qi *et al.*, 1994) y OSAVI (Rondeaux *et al.*, 1996).
- 3) índices corregidos atmosféricamente: GEMI (Pinty y Verstraete, 1992).

Por otro lado Silleos, *et al.*, (2006) clasifican a los índices en: índices de vegetación basados en pendiente e índices de vegetación basados en la distancia (ver Figura 6 y Figura 7). Los IV basados en pendiente son combinaciones aritméticas simples que se centran en el contraste entre los patrones de respuesta espectral de la vegetación en las partes de color rojo y del infrarrojo cercano del espectro electromagnético. En contraste, el grupo basado en la distancia mide el grado de la vegetación presente midiendo la diferencia de reflectancia de cualquier píxel de la reflectancia de suelo desnudo; un concepto clave aquí es que el gráfico de las posiciones de píxeles de suelo desnudo de diferentes niveles de humedad en la parcela bi-espectral tenderá a formar una línea (conocida como línea del suelo).

A medida que crece vegetación sobre un tipo de suelo determinado (ver Figura 5) disminuye la reflectividad en el rojo (R) y aumenta en el infrarrojo cercano (IRC), por lo que el punto va separándose de la línea del suelo en sentido ascendente y hacia la izquierda (A'). Cuando esto tiene lugar sobre cualquier tipo de suelo, aparece en el plano de IRC-R el denominado triángulo de reflectividades, característico de la presencia de vegetación. La distancia de cada uno de estos puntos a la línea del suelo será, por tanto, proporcional a la cantidad de vegetación. En este contexto, el diseño de índices consiste en definir una métrica con la cual medir la distancia en

los puntos representativos de cubiertas vegetales a la línea de suelo (Gilabert *et al.*, 1997)




Figura 5. Esquema de la línea del suelo. Definida en el plano de reflectividades IRC-R: El punto A corresponde a un suelo desnudo y el A' al mismo suelo recubierto con una cierta cantidad de vegetación.

Fuente: (Gilabert *et al.*, 1997)

Los principales índices de vegetación se presentan en la Figura 6 y Figura 7.

SLOPE BASED VEGETATION INDICES	Explanation of symbols	Author
$RATIO = \frac{NIR}{R}$	NIR = near infrared, R = red,	Birth and McVey (1968)
$NDVI = \frac{NIR-R}{NIR + R}$	B = blue, L = Soil	Rouse <i>et al.</i> (1974)
$SAVI = \frac{NIR-R}{(NIR + R)}(1+L)$	adjustment factor, C ₁ and C ₂ are constants, G is a gain factor	Huete (1988)
$TVI = \sqrt{\frac{(NIR-R)}{NIR + R}} + 0.5$		Deering <i>et al.</i> (1975)
$CTVI = \frac{NDVI + 0.5}{ABS(NDVI + 0.5)} \times \sqrt{ABS(NDVI + 0.5)}$		Perry and Lautenschlager (1984)
$TTVI = \sqrt{ABS(NDVI + 0.5)}$		Thiam (1997)
$RVI = \frac{R}{NIR}$		Richardson and Wiegand (1977)
$NRVI = \frac{RVI - 1}{RVI + 1}$		Baret and Guyot (1991)
$EVI = G \frac{NIR - R}{NIR + C_1R - C_2B + L} (1+L)$		Huete <i>et al.</i> (1999)

Figura 6. Índices de vegetación basados en la pendiente

Fuente: (Silleos, *et al.*, 2006)

SLOPE BASED VEGETATION INDICES	Explanation of symbols and author
$PVI = \sqrt{(R_{gg5} - R_{p5})^2 + (R_{gg7} - R_{p7})^2}$	Where R_p is the reflectance at a vegetation spot for Landsat bands MSS5 and MSS7, and R_{gg} is the reflectance of soil background (Richardson and Wiegand, 1977)
$PVI1 = \frac{(bNIR - R) + a}{\sqrt{b^2 + 1}}$	NIR = reflectance in the near infrared band R = reflectance in the visible red band a = intercept of the soil line b = slope of the soil line (Perry and Lautenschlager, 1984)
$PVI2 = \frac{(NIR - a) * (R + b)}{\sqrt{1 + a^2}}$	Similar to PVI (Bannari <i>et al.</i> , 1996)
$PVI3 = apNIR - bpR$	pNIR = reflectance in the near infrared band pR = reflectance in the visible red band a = intercept of the soil line b = slope of the soil line (Qi <i>et al.</i> , 1994)
$DVI = gMSS7 - MSS5$	g = the slope of the soil line MSS7 = reflectance in the near infrared 2 band MSS5 = reflectance in the visible red band (Richardson and Wiegand, 1977)
$AVI = 2.0 MSS7 - MSS5$	Similar to DVI (Ashburn, 1978)
$TSAVI1 = \frac{a(NIR - a)(R - b)}{R + a * NIR - a * b}$	NIR = reflectance in the near infrared band (expressed as reflectances) R = reflectance in the visible red band (expressed as reflectances) a = slope of the soil line b = intercept of the soil line (Baret <i>et al.</i> , 1989)
$TSAVI2 = \frac{a(NIR - aR - b)}{R + aNIR - ab + 0.08(1 + a^2)}$	Similar to TSAVI1 (Baret and Guyot, 1991)
$MSAVI1 = \frac{NIR - R}{NIR + R + L} (1 + L)$	NIR = reflectances in the near infrared band R = reflectances in the visible red band L = 1 - 2 NDVI * WDVI (Qi <i>et al.</i> , 1994)
$MSAVI2 = \frac{2pNIR + 1 - \sqrt{(2pNIR + 1)^2 - 8(pNIR - pR)}}{2}$	pNIR = reflectance of the near infrared band pR = reflectance of the red band (Qi <i>et al.</i> , 1994)
$WDVI = pNIR - \gamma pR$	pNIR = reflectance of near infrared band pR = reflectance of visible red band γ = slope of the soil line (Richardson and Wiegand, 1977; Clever, 1988)

Figura 7. Índices de vegetación basados en la distancia

Fuente: (Silleos, *et al.*, 2006)

3.7.1 Índice de vegetación de diferencia normalizada (NDVI)

El NDVI corresponde a una medida relativa, acerca del verdor o vigor de la vegetación contenida en los píxeles de la imagen.

El índice de vegetación de diferencia normalizada fue introducido por Rouse *et al.* (1974) con el fin de producir un índice espectral que separe la vegetación verde de la reflectancia del suelo, usando imágenes del satélite. Se expresa como la diferencia entre las bandas del infrarrojo y rojo cercano, normalizado por la suma de esas bandas. Es el índice más comúnmente utilizado ya que conserva la capacidad de minimizar el efecto topográfico mientras se produce una escala de medición lineal. Además los errores de división por cero se reducen significativamente. Por otra parte, la escala de medición tiene una propiedad deseada de rango que va de -1 a 1, donde 0 representa la aproximación del valor sin vegetación y los valores negativos indican ausencia de vegetación (Silleos *et al.*, 2006).

El NDVI ha sido uno de los índices de vegetación más empleados como indicador del estado de la vegetación, donde se está aprovechando la máxima absorción producida en el canal rojo debido a los pigmentos de la clorofila y a la máxima reflectividad producida en el infrarrojo debido a la estructura celular de las hojas. El principal inconveniente de este índice de vegetación radica en su tendencia a saturarse en cubiertas vegetales moderadas o densas (Martín *et al.*, 2011).

La obtención del índice de vegetación de diferencia normalizada se calcula mediante el siguiente cociente:

$$NDVI = \frac{R_{NIR} - R_{Roja}}{R_{NIR} + R_{Roja}} \quad (1)$$

Donde:

R_{NIR} : Reflectancia de la banda del infrarrojo cercano

R_{Roja} : Reflectancia de la banda del rojo visible

3.7.2 Índice de vegetación de diferencia ponderada (WDVI)

El índice de vegetación de diferencia ponderada (Weighted Difference Vegetation Index) fue especialmente desarrollado para corregir las mediciones de la reflectancia de la banda infrarroja de los cultivos, debido a la variación de la humedad contenida de la cubierta del suelo. Este índice tiene buena corrección en la variación de las condiciones de iluminación (ángulo de elevación solar y fracción directa/difusa de irradiancia) (Bouman, 1992). El índice de vegetación de diferencia ponderada, desarrollado por Clevers apareció especialmente idóneo para la estimación del índice de área foliar y cubierta de suelo. Aunque simple, WDVI es tan eficiente como la mayoría de los índices que usan la pendiente del suelo. El efecto de la ponderación de la banda roja con la pendiente de la línea del suelo es la maximización de la señal de la vegetación en la banda infrarroja y la maximización del efecto de la reflectancia del suelo (Silleos *et al.*, 2006).

El Índice de vegetación de diferencia ponderada se obtiene mediante la siguiente ecuación:

$$WDVI = R_{NIR} - y * R_{Roja} \quad (2)$$

Donde:

R_{NIR} : Reflectancia de la banda del infrarrojo cercano

R_{Roja} : Reflectancia de la banda de rojo visible

y : Pendiente de la línea del suelo

3.8. Tipos de evaluación de exactitud

De acuerdo con Congalton (2009), hay dos tipos de evaluación de la exactitud del mapa: posicional y temática:

La exactitud posicional se ocupa de la precisión de la localización de las características del mapa y mide que tan lejos está un elemento espacial de su ubicación real. La exactitud temática se ocupa de las etiquetas o los atributos de las entidades de un mapa y mide si las etiquetas asignadas son diferentes de la etiqueta característica verdadera.

La precisión de cualquier mapa o conjunto de datos espaciales es una función tanto de la precisión posicional y exactitud temática. Sin embargo la precisión temática es mucho más compleja que la exactitud posicional.

En la matriz de error, la precisión global de la clasificación se obtiene dividiendo la suma de los valores de la diagonal principal entre el tamaño de la muestra. La precisión del usuario es un indicador de errores de omisión y se calcula dividiendo el número de aciertos por el total de muestras en la hilera correspondiente. La precisión del productor del mapa es un indicador de errores de inclusión y se calcula dividiendo el número de aciertos entre el número total de muestras en la columna (Macedo *et al.*, 2010).

3.8.1 La matriz de error

En la década de 1980, la matriz de error se convirtió en una herramienta común para la representación de la exactitud de las categorías individuales del mapa. La matriz de error es un inicio apropiado para muchas técnicas de análisis estadístico, especialmente técnicas multivariadas discretas.

El enfoque de la matriz de error sólo es adecuado para clasificación "dura", en el supuesto de que las categorías del mapa son mutuamente excluyentes y exhaustivas y que cada lugar pertenece a una sola categoría. Este supuesto es a menudo violado, especialmente para las clasificaciones con una resolución espacial de imágenes muy grande (Lu y Weng, 2007).

Una matriz de errores es una matriz cuadrada de números organizados en filas y columnas que expresan el número de unidades de la muestra (píxeles, grupos de píxeles, o polígonos) asignadas a una categoría particular en relación con la categoría real como lo indican los datos de referencia (Figura 8). Las columnas representan típicamente los datos de referencia y las filas indican el mapa generado a partir de los datos de teledetección. Los datos de referencia se suponen correctos y se pueden coleccionar a partir de una variedad de fuentes, incluyendo la interpretación fotográfica, observación de tierra o campo, y la medición en campo (Congalton, 2004).

		Reference Data				Row total	
		D	C	AG	SB		
Classified Data	D	63	4	22	24	113	<u>Land Cover Categories</u> D = deciduous C = conifer AG = agriculture SB = shrub
	C	6	79	8	8	101	
	AG	0	11	85	11	107	
	SB	4	7	3	89	103	
Column total		73	101	118	132	424	
		<u>PRODUCER S ACCURACY</u>		<u>USER S ACCURACY</u>		OVERALL ACCURACY = (63 + 79 + 85 + 89)/424 = 316/424 = 75%	
		D = 63/73 = 86%		D = 63/113 = 56%			
		C = 79/101 = 78%		C = 79/101 = 78%			
		AG = 85/118 = 72%		AG = 85/107 = 79%			
		SB = 89/132 = 67%		SB = 89/103 = 86%			

Figura 8. Ejemplo de matriz de error
Fuente: Congalton, 2004

De acuerdo con Congalton, 2004, un paso analítico para interpretar, una vez que la matriz de error ha sido construida es "normalizar" o estandarizar la matriz usando la técnica conocida como " MARGFIT". Esta técnica utiliza un procedimiento de ajuste proporcional interactivo que obliga a cada fila y columna en la matriz a sumar uno. Las filas y columnas totales son llamadas marginales, de ahí el nombre de la técnica, MARGFIT. De esta manera, las diferencias en tamaño de las muestras utilizadas para generar las matrices se eliminan y, por lo tanto, los valores de las celdas individuales dentro de la matriz son directamente comparables. También, debido a que el proceso iterativo suma las filas y columnas, la matriz normalizada resultante es más indicativa de los valores de las celdas fuera de la diagonal (es decir, los errores de omisión y comisión) comparada con la matriz original. La diagonal mayor de la matriz normalizada puede ser sumada y dividida por el total de la matriz para calcular una precisión global normalizada.

La tabla de contingencia o matriz de error ha sido ampliamente aceptada como método estándar para informar de la precisión de las capas de datos de SIG derivados de datos obtenidos por teledetección. Una vez generada correctamente la matriz de error, se puede utilizar como punto de partida para una serie de técnicas estadísticas descriptivas y analíticas como: general, del productor, del usuario, así como información de tamaño de la muestra por categorías y totales. La estadística descriptiva más común y más simple es la precisión global, que se calcula dividiendo el total correcto (es decir, la suma de la diagonal mayor) entre el número total de unidades de la muestra en la matriz de error. Además, es un punto de partida para una variedad de instrumentos de análisis, incluyendo la normalización y el análisis de Kappa.

Una matriz de error es una manera eficaz de representar exactitud, porque tanto las precisiones totales e individuales de cada categoría se describen claramente y la confusión entre las clases es evidente. También se indican los errores de inclusión (errores de comisión) y los errores de exclusión (errores de omisión) que pueden

estar presentes en la clasificación. Un error de la comisión se produce cuando una zona está incluida en una categoría a la cual no pertenece. Un error de omisión está excluyendo una zona de la categoría en la que se pertenece. Cada error es una omisión en la categoría correcta y una comisión a una categoría incorrecta.

Tradicionalmente, el número total de unidades correctas de la muestra en una categoría se divide por el número total de unidades de muestra de esa categoría a partir de los datos de referencia (es decir, el total de la columna). Esta medida de precisión se refiere a la probabilidad de que una unidad de muestra de referencia sea clasificada correctamente y es en realidad una medida de error de omisión. Esta medida de precisión es a menudo llamada la *precisión del productor* debido a que el productor de la clasificación está interesado en lo bien que un área determinada se puede clasificar. En otras palabras, si el número total de unidades de muestra correctas en una categoría se divide por el número total de unidades de muestra que fueron clasificados en esa categoría en el mapa (es decir, el total de filas), éste resultado es una medida de la comisión de error. Esta medida se llama la precisión o confiabilidad de usuario y es indicativo de la probabilidad de que una unidad de la muestra clasificada en el mapa representa en realidad esa categoría en el suelo (Congalton, 2004).

Después de la generación de una matriz de error, otros elementos de evaluación de exactitud importantes, como la precisión global, error de omisión, error de comisión, y el coeficiente kappa, se pueden derivar (Lu y Weng, 2007).

3.8.2 Análisis Kappa

El análisis de Kappa es reconocido como un método poderoso para el análisis de una única matriz de error y para comparar las diferencias entre diversas matrices de error. Es una técnica multivariada discreta utilizada en la evaluación de la precisión para determinar estadísticamente si una matriz de error es significativamente diferente de otra (Bishop *et al.*, 1975, citado por Congalton, 2009).

Según Congalton (2009), esta medida se basa en la diferencia entre el arreglo actual en la matriz de error (es decir, el arreglo entre la clasificación de teledetección y los datos de referencia, como se indica por la gran diagonal) y la posibilidad de acuerdo que se indica mediante la fila y columna totales (es decir, los marginales). De esta manera, el estadístico del análisis Kappa es similar al más conocido Ji-cuadrada.

El análisis Kappa se puede utilizar como otra medida de acuerdo o exactitud. Los valores del índice Kappa pueden oscilar entre 1 y -1. Sin embargo, ya que hay una correlación positiva entre la clasificación de teledetección y los datos de referencia, se espera que los valores sean positivos.

Usando esta técnica es posible comprobar si una correlación individual de la cubierta vegetal generada a partir de datos obtenidos por teledetección es significativamente mejor que un mapa generado mediante la asignación etiquetas al azar a las áreas (Congalton, 2004).

Este índice es muy intuitivo y fácilmente interpretable: tomará valores entre 0 (total desacuerdo) y 1 (máximo acuerdo) (ver Cuadro 1). Sin embargo, como indicador de reproducibilidad tiene el inconveniente de que, aun en el caso de que los dos observadores clasifiquen con criterios independientes se produciría un cierto grado de acuerdo por azar. Puede haber coincidencia en el resultado sin que exista nada más que el puro azar, no el mismo criterio en la decisión. Es deseable que un índice de concordancia tenga en cuenta éste hecho y que, de algún modo, indique el grado de desacuerdo que existe por encima del esperado por azar (Abraira, 2001).

Warrens (2010) calcula el índice kappa (K), como

$$k = \frac{p_o - P_e}{1 - P_e} \quad (3)$$

$$P_e = \sum_{i=1}^c p_{i+} * p_{+i} \quad (4)$$

$$p_{i+} = \sum_{j=1}^c p_{ij} \quad (5)$$

$$p_{+j} = \sum_{i=1}^c p_{ij} \quad (6)$$

$$P_o = \sum_{i=1}^c p_{ii} \quad (7)$$

$$p_{ij} = \frac{n_{ij}}{m} \quad (8)$$

Donde:

P_o : Proporción de acuerdos observados

P_e : Proporción de acuerdos esperados

n_{ij} : Número de objeto en la categoría i por el primer evaluador y en la categoría j por el segundo evaluador

p_{ii} : Proporción de objetos colocados en la misma categoría por los dos evaluadores

c : Número de categorías

Cuadro 1. Valoración del coeficiente Kappa

Kappa (κ)	Grado de acuerdo
< 0,00	Sin acuerdo
0,00-0,20	Insignificante
0,21-0,40	Mediano
0,41-0,60	Moderado
0,61-0,80	Sustancial
0,81-1,00	Casi perfecto

3.9. Satélite RapidEye

RapidEye fue lanzado en agosto de 2008, está compuesto de cinco constelaciones de sensores multispectrales con una distancia de muestreo del terreno de 6,5m y un paso de todos los días. El satélite tiene una vida útil prevista de siete años y su destino de aplicación hacia la agricultura, por lo que tiene un alto potencial para la aplicación de la vigilancia agrícola. Los cinco satélites están equipados con

sensores idénticos y situados en el mismo plano orbital, lo que multiplica su capacidad de revisita y de captación de imágenes, orbitan a una altura de 630 km sobre la superficie terrestre (Labrador *et. al.*, 2012).

La constelación fue construida por SSTL (Surrey Satellite Technology Ltd) y destaca por el pequeño tamaño de los satélites (alrededor de 1 m³). En conjunto, los 5 satélites son capaces de cubrir una superficie de 4 millones de km² por día (Labrador *et. al.*, 2012).

El ancho de barrido (77 km) y el trabajo conjunto de los cinco satélites clónicos permite una revisita diaria. El sensor que lleva cada uno de los satélites proporciona cinco bandas espectrales con las características mostradas en el Cuadro 2. (Labrador, *et. al.*, 2012)

Cuadro 2. Bandas Espectrales de la constelación RAPIDEYE

Banda	Región espectral	Ancho de banda (nm)	Resolución (m)
1	Azul	440-510	5.0
2	Verde	520-590	
3	Rojo	630-685	
4	Rojo lejano	690-730	
5	NIR	760-850	

Fuente: Satelites para la teledetección (Labrador, *et al.*, 2012)

Las imágenes RapidEye poseen una resolución espacial de 5 metros, son adquiridas en cinco bandas espectrales: azul, verde, roja, infrarrojo cercano y borde rojo, siendo esta última banda importante ya que mide las variaciones en la vegetación, permitiendo la separación de las especies y la monitorización de la salud vegetal (RapidEye). Dependiendo del grado de procesado, Rapideye suministra dos tipos de imágenes (Labrador *et. al.*, 2012):

•**Nivel 1B:** Imagen corregida radiométricamente y sin las distorsiones que se producen por el escaneado y la óptica del sensor. Se suministra con los archivos RPC (Rational Polynomial Coefficient) correspondientes y los metadatos necesarios para que el usuario realice las correcciones geométricas necesarias.

•**Nivel 3A:** Además de las correcciones que se realizan para el nivel 1B, la imagen es ortorrectificada con un modelo de elevación del terreno y con puntos de control en el terreno. Estas imágenes se entregan a una resolución de 5 m/píxel.

Las imágenes se sirven siempre con los 5 canales que registra el sensor. El tamaño de las mismas es de unos 77 km de ancho y entre 50 y 300 km de largo.

.

4. MATERIALES Y MÉTODOS

4.1. Descripción del área de estudio

4.1.1 Ubicación

La zona de estudio corresponde al Distrito de Riego 017, comprende los Municipios de Gómez Palacio, Lerdo, Tlahualilo, Nazas, Rodeo, Mapimí, San Juan de Guadalupe y Simón Bolívar, localizados en la porción noreste del estado de Durango y los municipios de Torreón, Matamoros, San Pedro de las Colonias, Francisco I. Madero y Viesca, ubicados en la porción suroeste del estado de Coahuila (Figura 9).

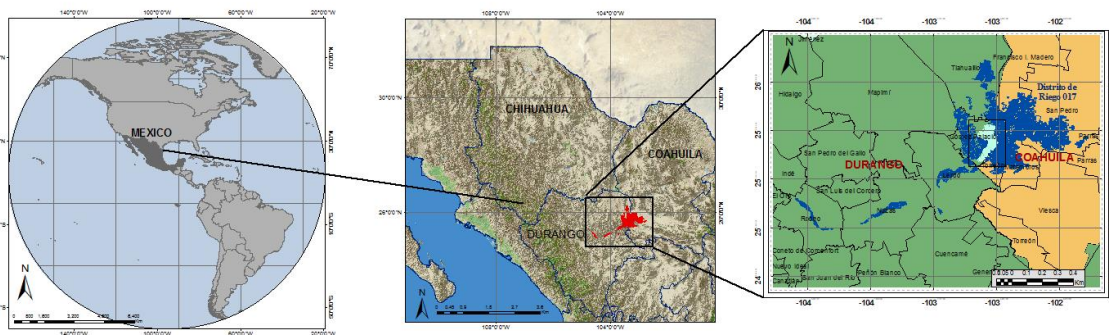


Figura 9. Zona de estudio

A nivel nacional, la región en donde se localiza el Distrito de Riego se ubica en la parte central de la porción norte de la República Mexicana, entre los meridianos $102^{\circ} 22' 00''$ y $104^{\circ} 47' 00''$ de Longitud Oeste y los paralelos $24^{\circ} 22' 00''$ y $26^{\circ} 23' 00''$ Latitud Norte; la altura sobre el nivel del mar es de 1,139 m.

El relieve presenta una extensión montañosa y una superficie plana, esta última donde se localizan las áreas agrícolas y áreas urbanas. El sector hidráulico administrativamente forma parte de la Región VII Cuencas Centrales del Norte de la Comisión Nacional del Agua y de la Región Hidrológica No. 36 Nazas Aguanaval.

El Distrito de Riego 017 se encuentra dividido en forma general en tres zonas agrícolas, la primera localizada aguas abajo de la presa Lázaro Cárdenas que integra a los Módulos I y II, la segunda ubicada abajo de la presa Francisco Zarco que integra a los Módulos III al XVII y la tercera que comprende a los Módulos XVIII, XIX, y XX que se ubican prácticamente en las vegas del Río Aguanaval, desde el municipio San Juan de Guadalupe hasta el municipio de Matamoros.

4.1.2 Clima

En general en el Distrito de Riego 017 el clima predominante es el clima seco semidesértico, semicálido y extremoso, con humedad deficiente en todo el año.

En la región del Río Nazas se presentan climas que van desde el semiseco templado en la cuenca de la Presa Lázaro Cárdenas hasta el seco templado, semicálido y muy seco semicálido en la cuenca Nazas – Torreón.

En la cuenca de Nazas –Torreón en donde se localizan la mayor parte de los Módulos (III, IV, V, VI, VII, VIII, IX, X, XI, XII, XIII, XIV, XV, XVI), la precipitación total anual es menor a los 300 mm y la temperatura media anual es de 20° C.

4.1.3 Vegetación

Por su pendiente plana y por el tipo de clima, la vegetación predominante de la zona Cuenca del Río Nazas del distrito es la típica del semidesierto, predominan los matorrales, arbustos, palmas del desierto, Chaparral, y zacates.

La vegetación se distingue por la predominancia de elementos arbustivos de hoja pequeña. Esta constituido principalmente por la gobernadora (*Larrea tridentata*), el mezquite (*Prosopis laevigata* y *P. glandulosa*), biznagas (*Ferocactus sp.*), nopales (*Opuntia basilaris*, *O. duraguensis*, *O. leptocaulis*) y algunos elementos aislados

de yuca (*Yucca carnerosana*) y ocotillo (*Fouquieria splendens*) en el estrato arbustivo, así como una gran cantidad de herbáceas entre las que destacan las compuestas y gramíneas (Figura 10).



Figura 10. Vegetación predominante en el Distrito 017, Región Lagunera

4.2. Herramientas y software utilizado

La fase de campo consistió en la toma de datos e identificación de parcelas, por lo que fueron necesarias fotos en la zona de estudio, lo que se realizó con la ayuda de un equipo de cómputo (laptop), GPS, vehículo y cámara fotográfica, que son descritos con más detalle en el Cuadro 3.

Cuadro 3. Descripción del equipo de campo utilizado

Equipo	Características
Laptop	Pavilion dv4 Intel Core Duo 2.26 GHz, 4Gb en RAM 320 GB en disco duro.
GPS	eTrex 30 Pantalla de 2.2 pulgadas Brújula electrónica de 3 ejes y altímetro barométrico Receptor compatible con WASS y GLONASS
Vehículo	Camioneta Pickup (FORD Ranger)
Cámara Fotográfica	Sony CyberShot DSC-S930 Resolución de 10.1 Megapíxeles Zoom óptico 3x LCD de 2.4 pulgadas

En la fase de gabinete fue necesario contar con un equipo de cómputo que tuviera instalado el software ERDAS IMAGINE ® MICROSOFT EXCEL ® MICROSOFT WORD ® y ARC MAP 10. Se utilizaron imágenes RapidEye proporcionadas por la empresa alemana BlackBridge.

4.3. Metodología

En el presente trabajo se obtuvo un clasificador de los principales cultivos agrícolas sembrados en el ciclo primavera – verano de 2013 en el área que corresponde al Módulo X “Masitas” del Distrito de Riego 017 Región Lagunera en el estado de Coahuila, a partir de datos obtenidos de los valores de cada una de las bandas con las que cuentan las imágenes RapidEye.

El trabajo de la presente metodología se sintetiza en siete fases, la primera fase denominada adquisición de imágenes en la cual se detalla el número y fecha de cada una de las imágenes así como el área cubierta. La segunda fase nombrada pre-procesamiento de imágenes describe el tratamiento que se le dio a cada imagen antes de tomar información de ellas. La tercera fase, llamada verificación de parcelas en campo, detalla el número de parcelas de los diferentes cultivos establecidos en el módulo X “Masitas” que se referenciaron y usaron para el desarrollo de éste trabajo. En la cuarta fase se seleccionaron las parcelas de entrenamiento, en esta fase se re-digitalizaron las parcelas seleccionadas a fin de obtener información más confiable del centro de cada parcela. En la quinta fase designada asignación de los datos raster a los datos vectoriales se trasladó la información de las imágenes (raster) a cada parcela (vector). La sexta fase nombrada análisis de la información, detalla las características y diferencias en las firmas espectrales de los diferentes cultivos y en la séptima fase se desarrolla el clasificador de cultivos (ver Figura 11).

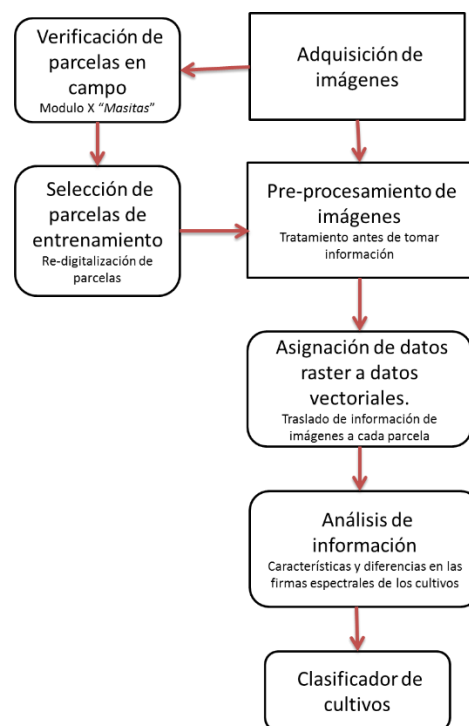







Figura 11. Fases para obtener el clasificador

4.3.1. Adquisición de las imágenes

Las imágenes se solicitaron a la empresa alemana Blackbridge con el fin de obtener coberturas del área de interés que incluyera la mayor parte del ciclo agrícola. Para cubrir el área que abarca el módulo se utilizó una imagen como se muestran en la Figura 12. Por cada imagen se entregaron los siguientes archivos (Cuadro 4):

Cuadro 4. Archivos entregados con cada imagen Rapideye

 1350921_2013-03-12_RE2_3A_157621.tif	Archivo que es propiamente la imagen
 1350921_2013-03-12_RE2_3A_157621_browse.tif	Una vista rápida de la imagen
 1350921_2013-03-12_RE2_3A_157621_license.txt	La licencia de uso de la imagen
 1350921_2013-03-12_RE2_3A_157621_metadata.xml	El archivo donde se encuentran los metadatos
 1350921_2013-03-12_RE2_3A_157621_readme.txt	Lista de archivos entregados
 1350921_2013-03-12_RE2_3A_157621_udm.tif	Imagen que muestra áreas que no se pueden usar.

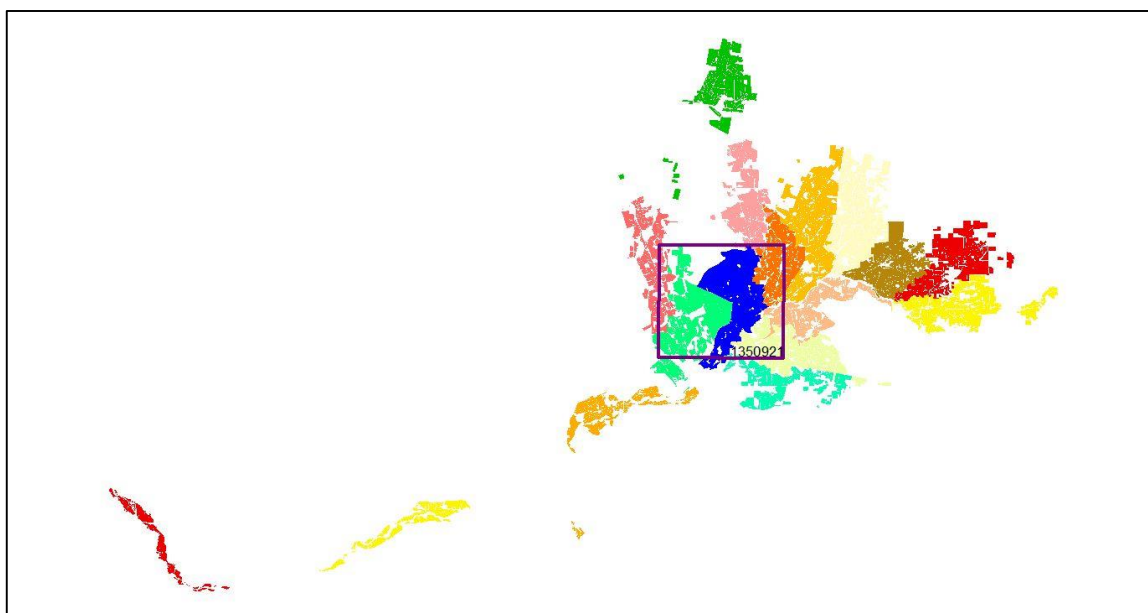


Figura 12. Imagen utilizada para cubrir el área del módulo X Masitas.

Fuente: Elaboración propia

El identificador de las imágenes fue 1350921 y las fechas de las imágenes para cada toma se muestran en el Cuadro 5. La proyección de las imágenes entregadas fue UTM zona 13, esferoide WGS84 y datum WGS84.

Cuadro 5. Imágenes RapidEye utilizadas para cubrir la zona de estudio.

Mes	Abril	Mayo	Junio	Julio
Fecha	17/04/2013 22/04/2013 29/04/2013	10/05/2013 25/05/2013	16/06/2013	15/07/2013 24/07/2013
Tile ID	1350921	1350921	1350921	1350921

Cada imagen identificada con un número de “tile” viene contenida en una carpeta junto con su metadato y una vista rápida de la imagen, como lo muestra la Figura 13.









		
17 de abril de 2013	22 de abril de 2013	29 de abril de 2013
		
10 de mayo de 2013	25 de mayo de 2013	16 de junio 2013
		
15 de julio de 2013	24 de julio de 2013	

Figura 13. Imágenes RapidEye adquiridas

La primera toma fue el día 17 de abril, que representa el día juliano 107 y la última toma fue del día 24 de julio, que representa el día juliano 205, cubriendo una ventana de tiempo de 98 días.

4.3.2. Pre-procesamiento de imágenes

El software que se utilizó fue ERDAS IMAGINE 2011 ® y ARCMAP 10.

El tratamiento que se les dio a las imágenes fue el siguiente: primero se convirtió de formato *tif* (formato en el que son entregadas las imágenes) a *img*, (formato de trabajo de ERDAS) posteriormente se georreferenciaron las imágenes utilizando como referencia la primera imagen adquirida. Una vez georreferenciadas las imágenes se convirtieron los valores de los números digitales (ND) a valores de reflectancia para poder aplicar la corrección atmosférica utilizando el método de sustracción de objetos oscuros y finalmente agregar a la imagen la fecha en que fue tomada.

Importación de imágenes de satélite: Las imágenes de satélite RapidEye se proporcionan en formato *tif*, por lo que se efectuó una conversión a formato *img*, proceso que en el software Erdas Imagine se conoce como importar (Figura 14).

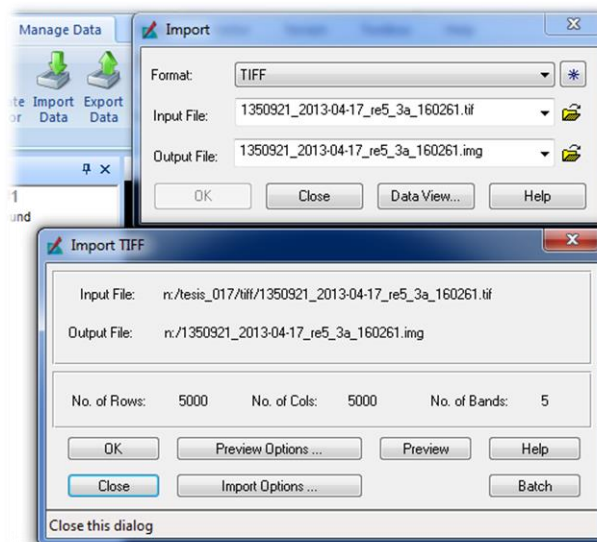


Figura 14. Importación de imágenes usando ERDAS

Georreferenciación de las imágenes usando como referencia la primera imagen de abril: Las imágenes fueron entregadas en el sistema de coordenadas UTM, esferoide WG84 y datum WGS84 en un nivel de procesamiento 3A, ortorectificadas, las cuales están corregidas radiométricamente y geoméricamente usando modelos de elevación de 30 a 90 m. por lo que su exactitud es buena, sin embargo, puede aún existir algún desfase entre toma y toma originado por la diferencia en el ángulo que fue tomada la imagen y la presencia de nubes. Debido a lo anterior, la imagen fue nuevamente georreferenciada utilizando el módulo AutoSync de ERDAS IMAGINE (Figura 15).

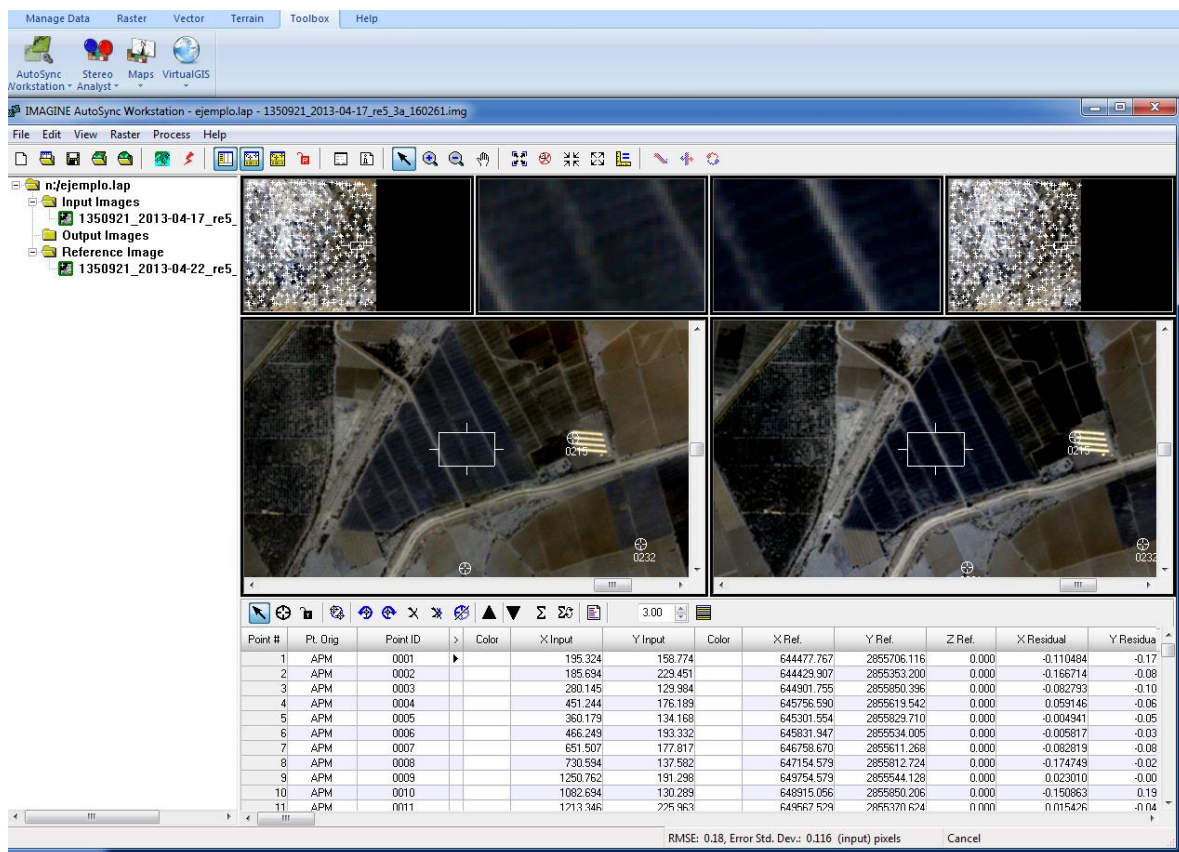


Figura 15. Georreferenciación usando Autosync de ERDAS

Se utilizó como referencia la imagen del 17 abril por ser la primera de la serie de imágenes recibidas, el método de re-muestreo fue convolución cúbica y en todos

los casos el cuadrado medio del error (RMS) fue menor a 0.6 es decir menor a 3 metros.

Conversión de valores de números digitales a reflectancia en el techo de la atmosfera: Para convertir los valores de los Números Digitales (ND) de cada una de las bandas a valores de reflectancia se usó la siguiente fórmula:

$$REF(i) = RAD(i) \frac{\pi * SunDist^2}{EAI(i) * \cos(SolarZenit)} \quad (8)$$

$$RAD(i) = DN(i) * Factor Radiometrico \quad (9)$$

Dónde:

- i = Número de banda espectral
- RAD =Valor de la radianza en el techo de la atmósfera
- REF= Valor de la reflectancia en el techo de la atmósfera
- Factor Radiométrico =0.01
- SunDist= Distancia tierra sol en unidades Astronómicas
- EAI = Irradianza Exo-Atmosférica
- SolarZenit= Angulo solar desde el Zenit = (90- ángulo de elevación solar)
- π =3.1416

Para RapidEye los valores de EAI son los siguientes:

Azul: 1997.8 W/m²μm

Verde: 1863.5 W/m²μm

Rojo: 1560.4 W/m²μm

Borde Rojo: 1395.0 W/m²μm

Infrarrojo cercano: 1124.4 W/m²μm

Los datos del ángulo de elevación solar y del día en que fue tomada la imagen se encuentran en el archivo “METADATA” el cual contiene los metadatos de la imagen (Figura 16).

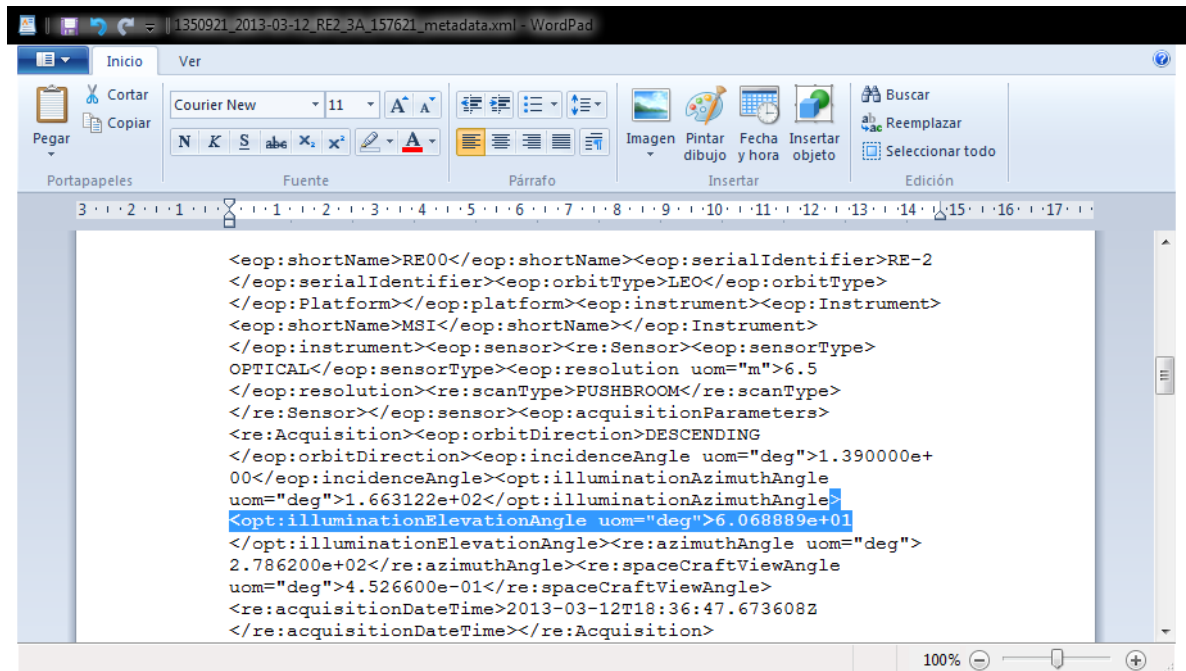


Figura 16. Archivo metadata de imagenes RapidEye

Una vez obtenidos los valores para cada banda se creó un modelo para reflectancia en ERDAS para esto se utilizó el módulo “MODEL MAKER” como se muestra en la Figura 17.

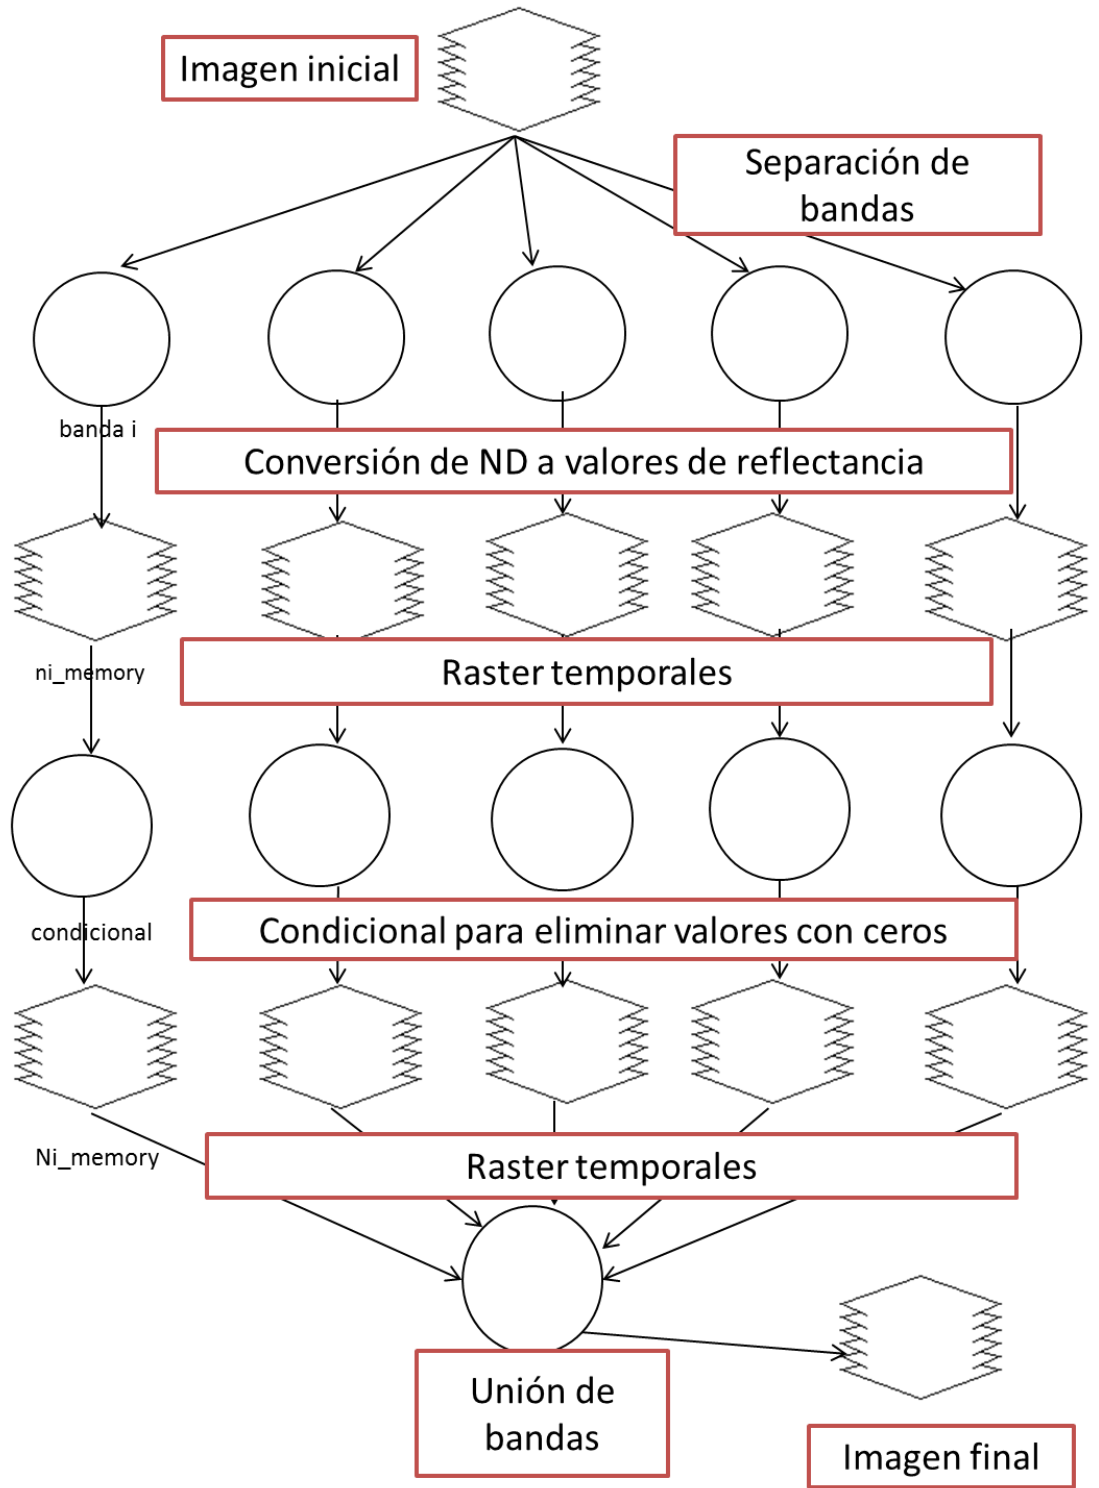


Figura 17. Modelo de reflectancia en ERDAS

Al final se obtuvieron las imágenes con valores de reflectancia expresados en porcentaje para cada una de las bandas. Los valores de reflectancia van de 0 a 1 pero se multiplicaron por un factor de 100 para trabajar en lo sucesivo con números enteros. Por lo que la reflectancia queda expresada en porcentaje (0 a 100).

Aplicar corrección atmosférica usando el método de sustracción de objetos oscuros: Para corregir el efecto de la atmósfera se utilizó el método de sustracción de objetos oscuros (Chávez, 1996), obteniendo el mínimo valor de reflectancia de cada una de las bandas y disminuyéndolo hasta el 2%; esto se logró consultando las estadísticas de las bandas de cada una de las imágenes (Figura 18) y de igual forma elaborando otro modelo en ERDAS (Figura 19) para aplicar las restas correspondientes.

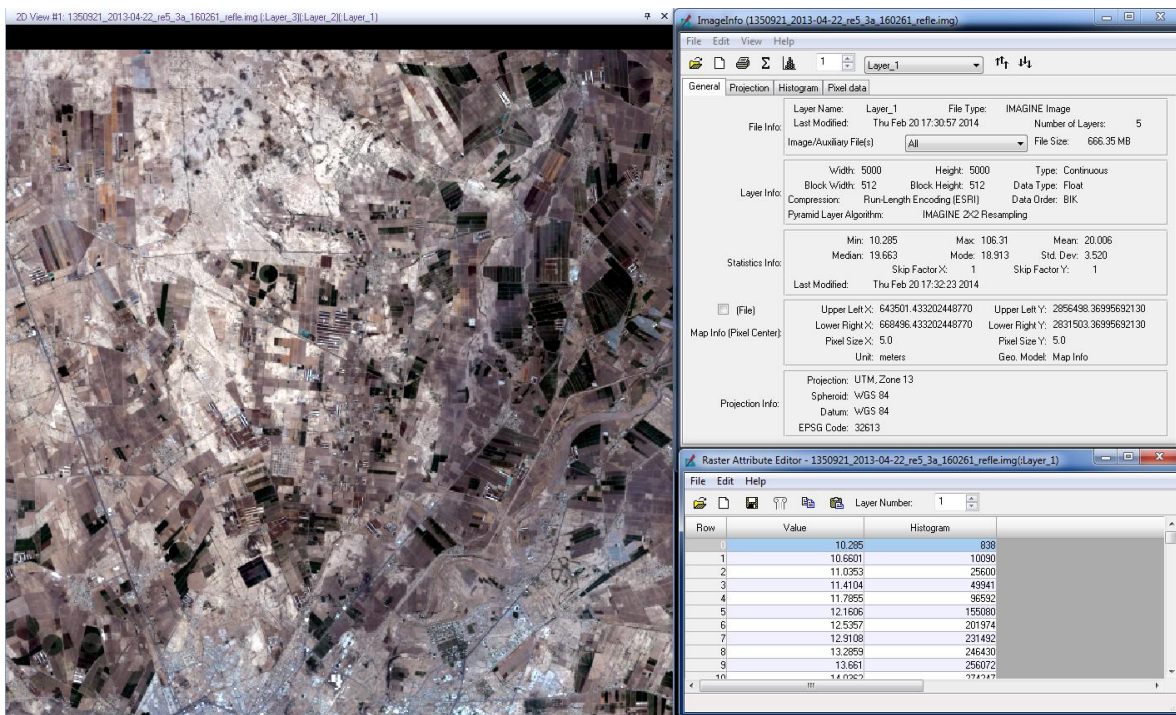


Figura 18. Valor mínimo de la banda 1 (10.285) para la imagen del 22 de abril

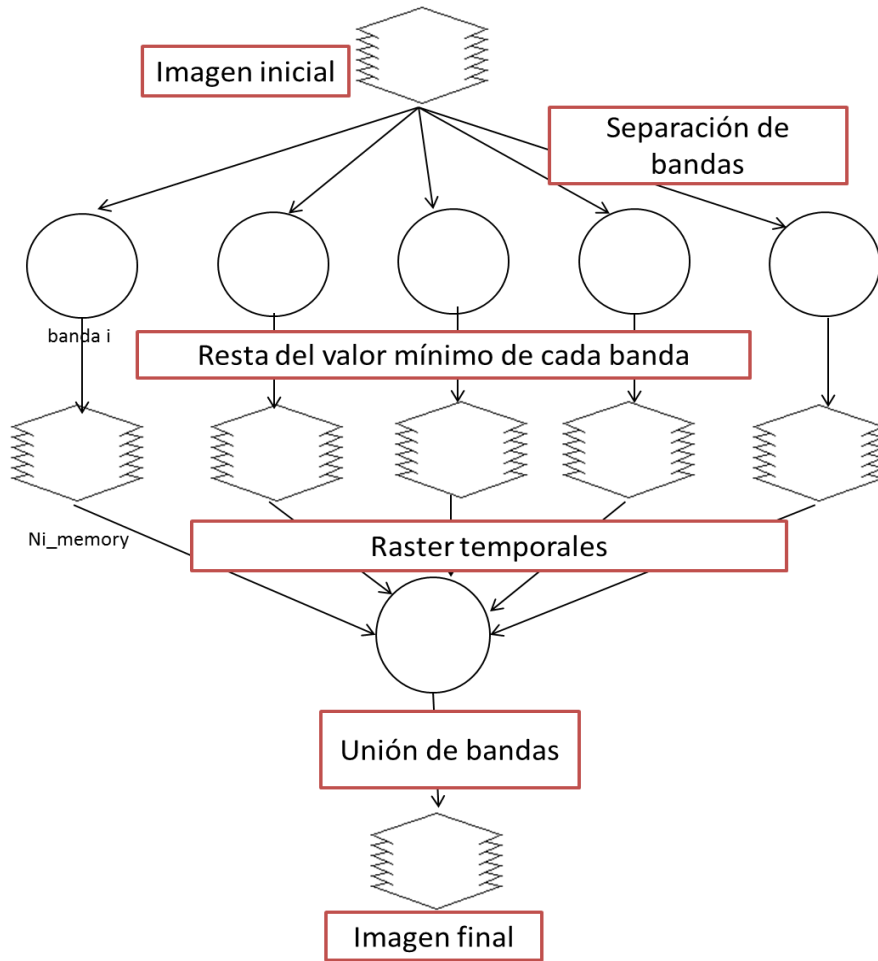


Figura 19. Modelo de sustracción de objetos oscuros en ERDAS

4.3.3. Verificación de parcelas en campo

Como parte de la supervisión 2013 en el Distrito de Riego 017 se identificó la superficie y el cultivo establecido en cada uno de los módulos. Para cada parcela supervisada se tomaron puntos con GPS y fotos de cada parcela analizada, la superficie fue calculada usando el software ARCGIS. La relación de cultivos encontrada se puede observar en el Cuadro 6 ordenados alfabéticamente por el nombre.

Cuadro 6. Parcelas muestreadas en campo.

CULTIVO	No parcelas	Superficie Calculada (ha)
ALFALFA	20	116.23
ALGODON	18	58.461
FRIJOL	3	2.134
MAIZ	172	1,217.74
MELON	1	0.694
NOGAL	27	185.345
SANDIA	8	13.047
SIN CULTIVO	10	26.467
SORGO	433	1,619.43
TOTAL	692	3,239.55

(Fuente: elaboración propia a partir de datos de campo)

4.3.4. Selección de parcelas de entrenamiento

De las 692 parcelas encontradas solo se seleccionaron cinco cultivos, que fueron los de mayor importancia para el ciclo primavera verano (ver Cuadro 7).

Cuadro 7. Número de parcelas por cultivo utilizados para en el análisis.

CULTIVO	PARCELAS	SUPERFICIE TOTAL(ha)
ALFALFA	9	22.06
ALGODON	10	28.51
MAIZ	20	157.73
NOGAL	12	91.01
SORGO	19	62.57
TOTAL	70	361.87

Posteriormente se procedió a revisar visualmente cada parcela del shapefile para realizar ajustes de dimensión. El criterio utilizado fue tener parcelas homogéneas y ubicadas con un shapefile que únicamente abarcara el área sembrada, como se puede observar en la Figura 20.




Figura 20. Modificación del shapefile para ajustar la dimensión de las parcelas

A fin de reducir los errores que se presentan en la zona frontera entre clases debido a que cada pixel depende de la distribución de sus valores vecinos (Fernandez *et al.*, 2003), se realizó un recorte al vector de las parcelas de 20 metros (4 pixeles). Como ejemplo se muestra la Figura 21.




Figura 21. Recorte aplicado a las parcelas seleccionadas

4.3.5. Asignación de los datos raster a los datos vectoriales

Debido a que lo que se estaba identificando eran parcelas, la unidad de muestreo que se utilizó fueron polígonos u objetos. Una vez obtenidas las imágenes y el vector de las parcelas seleccionadas se asignó el valor promedio de cada una de las cinco bandas utilizando para ello el módulo de "ZONAL ATTRIBUTES" (ERDAS, 1997) (ver Figura 22).

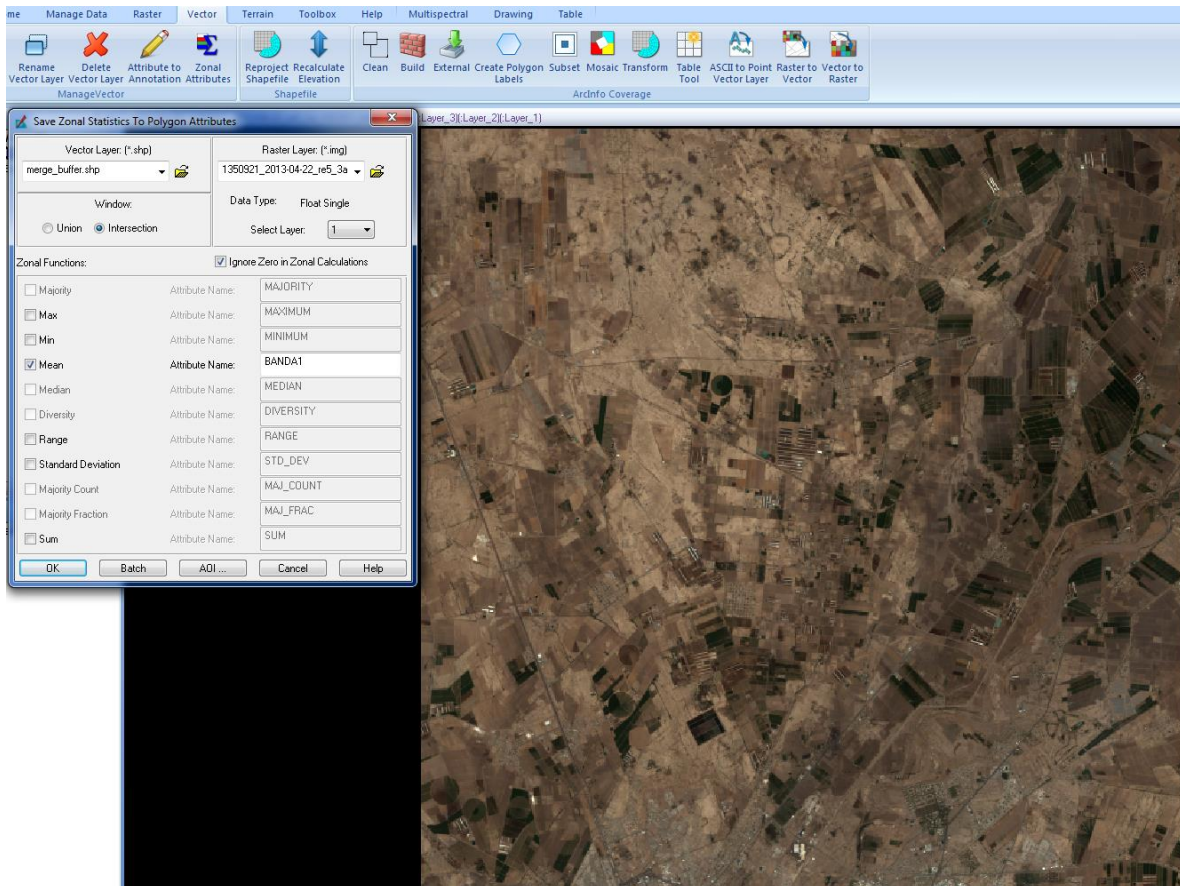


Figura 22. Asignación de datos raster al vector usando "ZONAL ATTRIBUTES"

4.3.6. Análisis de la información

Ya que se tuvo la información de los valores promedios de las bandas en el archivo “.dbf” del vector de parcelas se procedió a trabajar éste en una hoja de cálculo de Excel, separando los valores de las coberturas para cada cultivo como se muestra en la Figura 23. Cada parcela (fila de Excel) contuvo la siguiente información: valor promedio de la banda 1 (B1) a la banda 5 (B5) de la imagen. A partir de esta etapa se continuó trabajando en Excel.

	A	B	C	D	E	F	G
1	CULTIVO	BANDA1	BANDA2	BANDA3	BANDA4	BANDA5	
2	SORGO	11.176	14.068	20.219	19.803	24.768	
3	SORGO	9.526	12.113	17.435	17.059	21.558	
4	SORGO	9.759	12.320	18.280	17.632	22.135	
5	SORGO	10.572	13.253	19.089	18.361	22.936	
6	SORGO	11.657	14.712	20.792	20.184	25.012	
7	SORGO	10.334	12.831	18.684	18.003	22.562	
8	SORGO	10.793	13.833	19.968	19.399	24.045	
9	SORGO	11.393	14.482	20.805	20.249	25.122	
10	SORGO	10.684	13.388	19.334	18.761	23.534	
11	SORGO	9.006	11.511	16.473	15.994	20.953	
12	SORGO	9.638	12.116	17.058	16.561	21.211	
13	SORGO	9.475	12.178	17.536	17.217	22.201	
14	SORGO	9.597	11.730	16.497	15.888	20.601	
15	SORGO	9.224	11.420	16.284	15.483	19.647	
16	SORGO	9.157	11.284	16.381	15.799	20.276	
17	SORGO	10.372	13.213	19.192	18.567	23.024	
18	SORGO	13.973	18.004	25.569	24.834	30.119	
19	SORGO	13.107	16.582	23.513	22.649	27.543	
20	SORGO	12.402	16.006	22.631	22.033	27.318	
21	NOGAL	6.803	9.254	11.611	14.421	25.403	
22	NOGAL	7.245	9.736	12.024	15.562	27.516	
23	NOGAL	10.199	13.557	17.917	19.745	29.339	
24	NOGAL	8.926	11.362	15.079	17.138	27.139	
25	NOGAL	10.312	12.815	17.548	17.707	23.894	
26	NOGAL	7.002	9.583	11.862	14.908	25.710	
27	NOGAL	7.360	9.682	11.317	14.496	25.916	
28	NOGAL	7.890	10.357	12.758	15.294	25.623	
29	NOGAL	8.126	10.614	13.345	15.516	25.057	
30	NOGAL	7.368	9.931	12.236	15.159	26.124	
31	NOGAL	7.625	10.266	12.633	15.587	27.038	
32	NOGAL	7.941	10.706	13.298	16.149	27.382	

Figura 23. Datos trasladados a excel

Obtención del gradiente de la línea del suelo (g)

Para el cálculo del Índice de Vegetación de Diferencias Ponderadas (WDVI) se determinó primero el gradiente de la línea del brillo del suelo (g) seleccionando áreas sin cobertura vegetal. El gradiente g, calculado a partir de las parcelas que tienen suelo desnudo, es la pendiente de la relación de la banda del infrarrojo cercano y banda roja (Bouman, 1992) y su fórmula es la siguiente:

$$g = \frac{\text{Infrarrojo cercano}}{\text{rojo}} \quad (10)$$

g se obtuvo muestreando 20 áreas de parcelas con suelo desnudo y calculando el promedio de las bandas del rojo e infrarrojo cercano.

Calculo del WDVI

El WDVI resulta útil para estimar la cobertura vegetal del suelo (Silleos *et al.*, 2006). Por lo que para cada imagen se calculó el WDVI de la parcela con la formula siguiente:

$$WDVI = \rho_{NIR} - g * \rho_R \quad (11)$$

Donde:

g =1.3 para área de estudio obtenida en (10).

ρ_{NIR} = Reflectancia del banda del infrarrojo cercano .

ρ_R = Reflectancia de la banda Roja.

Caracterización de la firma espectral y WDVI de los diferentes cultivos en base a la fecha

Se analizó el comportamiento de las firmas a lo largo de la ventana de tiempo de las imágenes disponibles a fin de encontrar parámetros que pudieran diferenciar un cultivo de otro.

La firma espectral de cada cultivo tomando como elemento la parcela, cambia de acuerdo al estado fenológico de la planta (Ver Figura 32, Figura 36, Figura 39, Figura 45), las firmas espectrales de los diferentes cultivos pueden llegar a ser muy parecidas sin embargo pueden encontrarse algunas diferencias como se demostrará más adelante (ver Figura 54 a Figura 63) es por ello que se procedió a caracterizar cada firma espectral de los diferentes cultivos de acuerdo a la fecha en que cada imagen fue tomada.

Comparación entre firmas de los cinco cultivos

Se comparó en una sola gráfica las firmas espectrales de los cinco cultivos para identificar el comportamiento.

Comparación del WdVI de diferentes parcelas para un mismo cultivo a lo largo del ciclo

Se comparó variación del comportamiento del WdVI en las gráficas entre parcelas de un mismo cultivo.

Análisis Individual de las bandas espectrales a lo largo del ciclo

Con el fin de encontrar la banda espectral que menor variación tuvo a lo largo del ciclo se graficó de manera individual el comportamiento de las reflectancias de la banda verde, roja y borde rojo, a lo largo del ciclo.

Análisis Grafico-tabular de las parcelas

Una vez que se obtuvieron los valores, principalmente de WdVI, se procedió a comparar los índices promedio de cada parcela con su imagen correspondiente y el comportamiento visual a lo largo del ciclo.

Definición de los criterios de clasificación

Una vez hecho el análisis por cultivo se procedió a comparar firmas y relaciones entre cultivos a fin de definir los parámetros que se utilizaron en la elaboración del clasificador. Tomando como criterio para diferenciar el valor del WDVI, la banda 2 y la banda 3.

4.3.7. Elaboración del clasificador

Una vez encontrados los parámetros que más distinguían las firmas espectrales se procedió a programar los criterios de clasificación. Para ello se usó el lenguaje de programación de Visual Basic para aplicaciones (VBA) provisto en el paquete de Excel, el diagrama de flujo se muestra de la Figura 24 a la Figura 29. El clasificador se basa en comparar la firma en análisis con un banco de firmas espectrales a fin de eliminar posibles cultivos y tomando como criterio final la banda verde y roja (banda 2 y 3) de la imagen RapidEye.

Primera etapa

En la primera etapa se obtienen las firmas espectrales de los cinco cultivos tomando como base la firma espectral que coincida con la reflectancia de la banda 4 (borde rojo) de la parcela a analizar. Como no siempre será posible que las reflectancias coincidan, se toma como tolerancia una diferencia de +/- 0.5. Si no hay firma que cumpla estas condiciones no se comparará el cultivo de la parcela a analizar. El diagrama de la etapa 1 puede verse en la Figura 24.

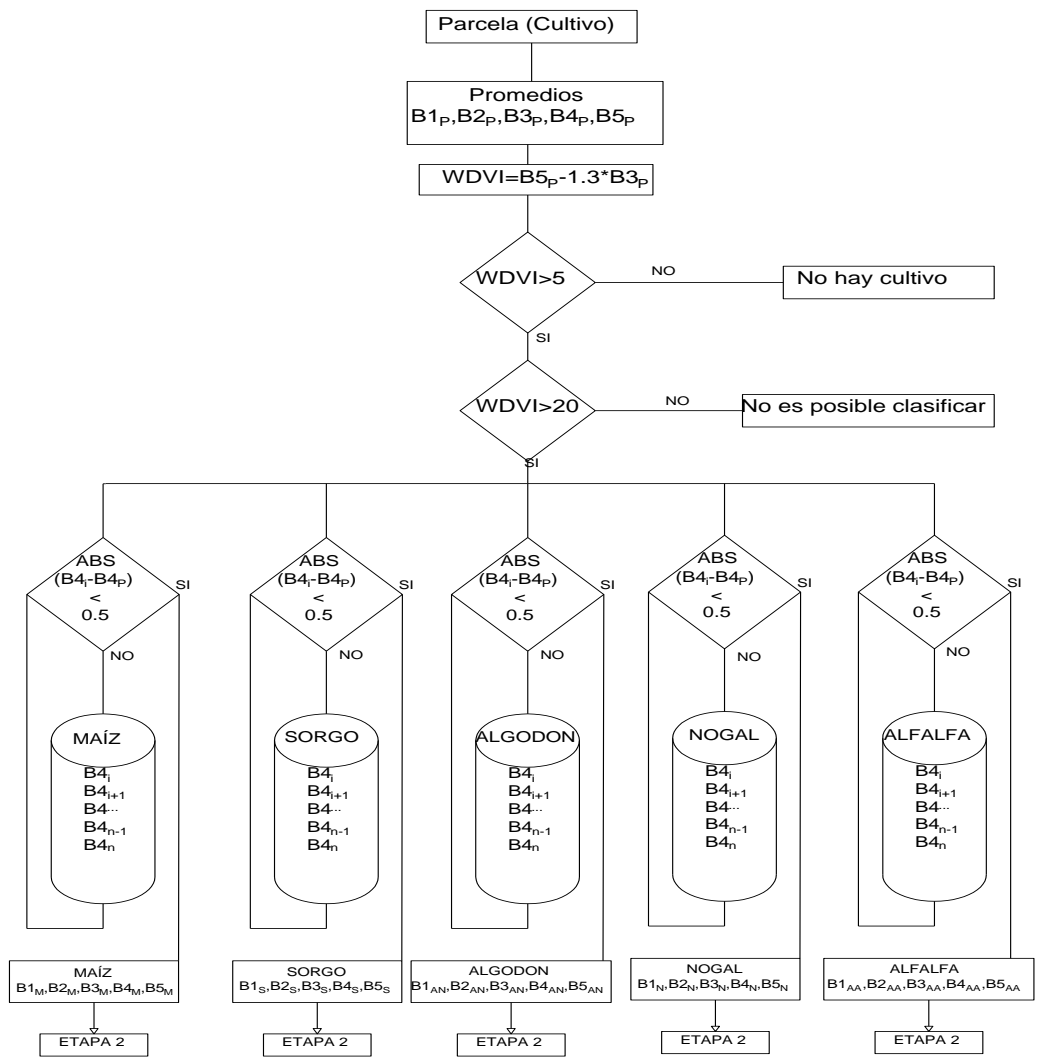


Figura 24. Etapa 1 del clasificador

Segunda etapa

En la segunda etapa se compara la firma espectral del cultivo de la parcela a analizar con las firmas de los cultivos obtenidos en la primera etapa. Esto se hace suponiendo que la firma a analizar se trata de uno de los cultivos y se compara con los cuatro restantes (Figura 25 y Figura 26).

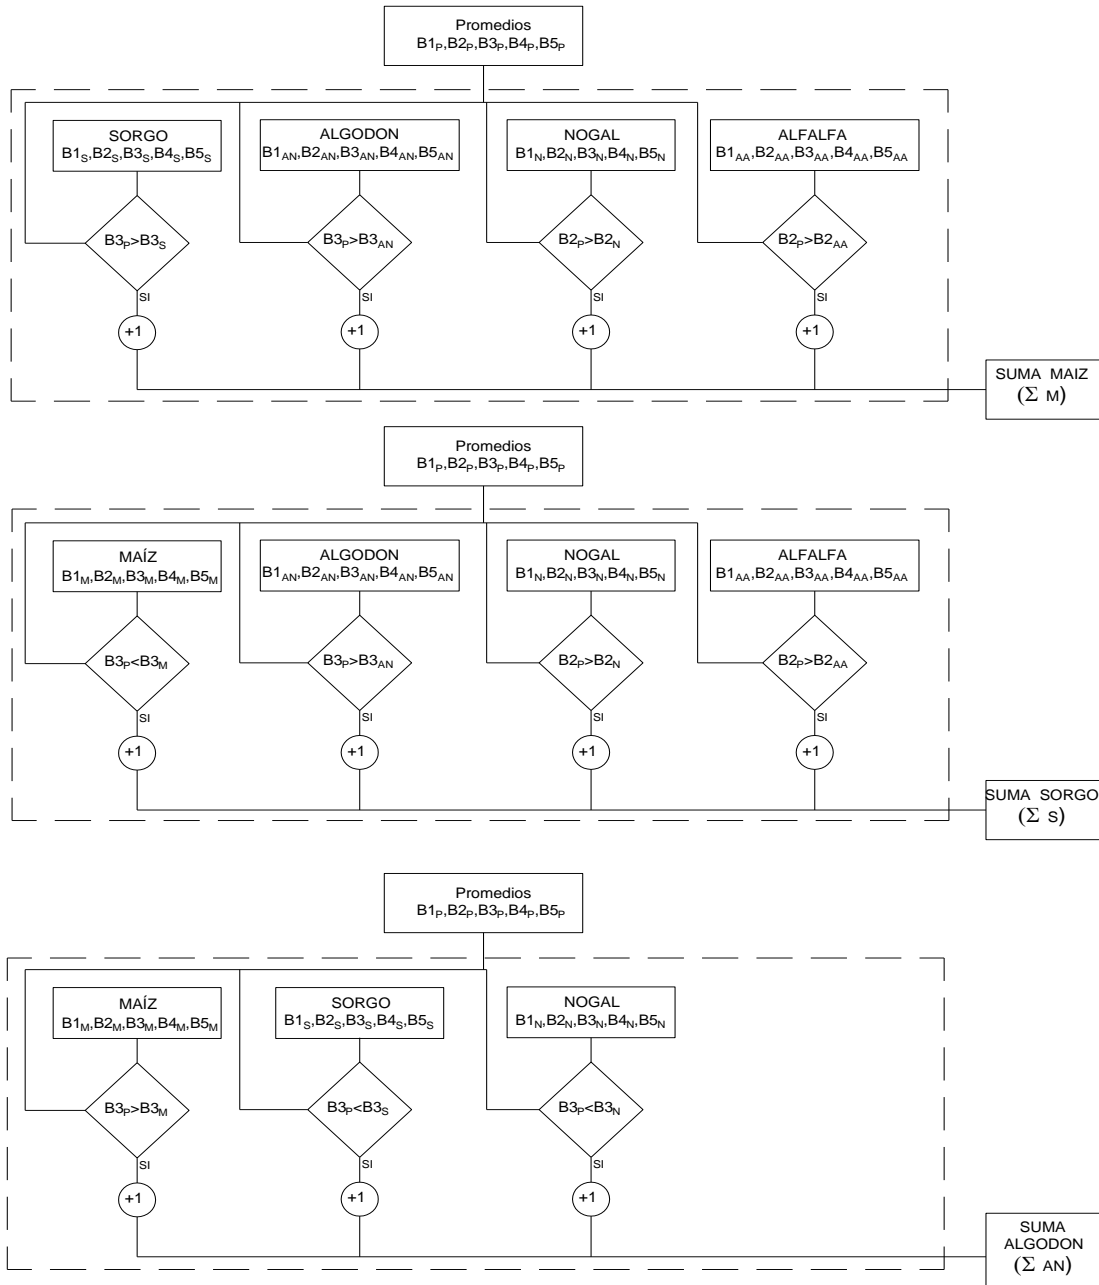


Figura 25. Etapa 2 del clasificador para los cultivos de maíz, sorgo y algodón.

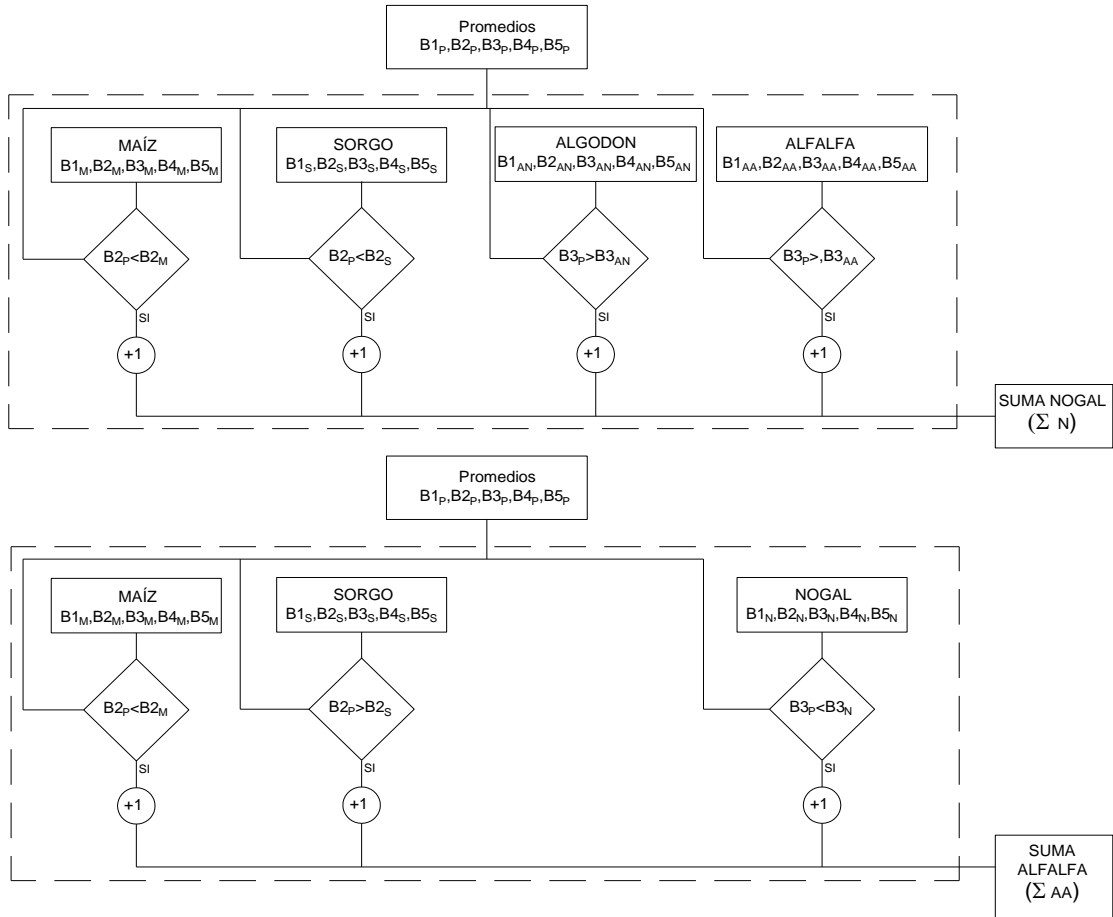


Figura 26. Etapa 2 del clasificador para los cultivos de nogal y alfalfa.

Tercera etapa

En la tercera etapa únicamente se encuentra la suma máxima (MAX) dentro de los 5 cultivos diferentes, el diagrama se puede observar en la Figura 27.

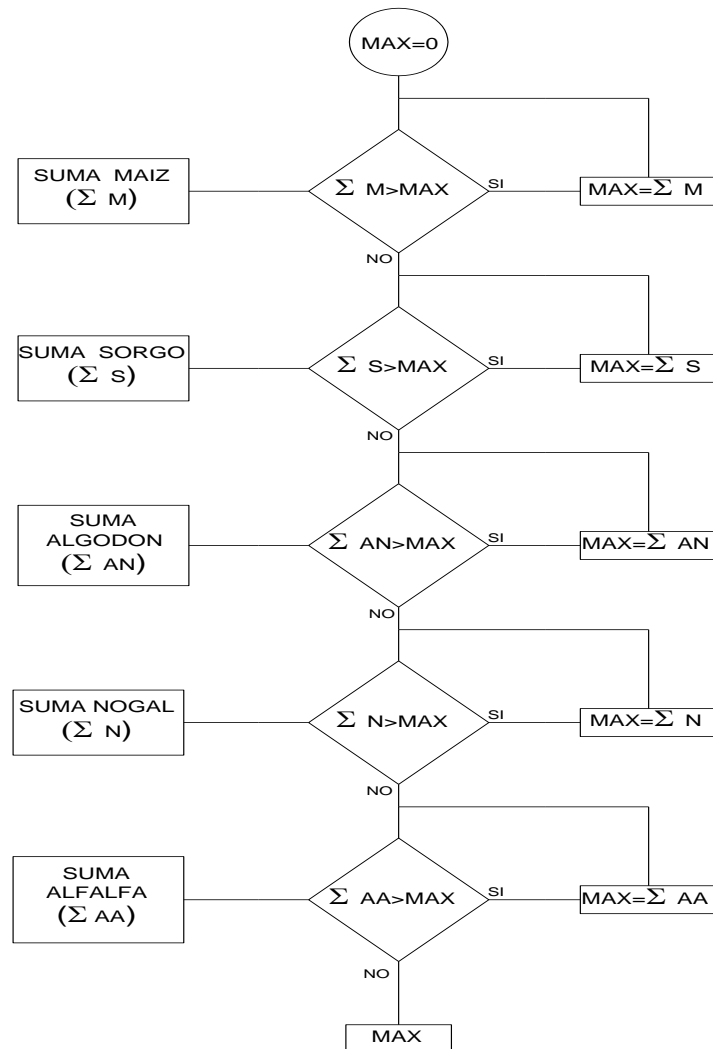


Figura 27. Etapa 3 del clasificador

Cuarta etapa

En la cuarta etapa determina si se encontraron más de un cultivo con la suma máxima. El diagrama se puede observar en la Figura 28.

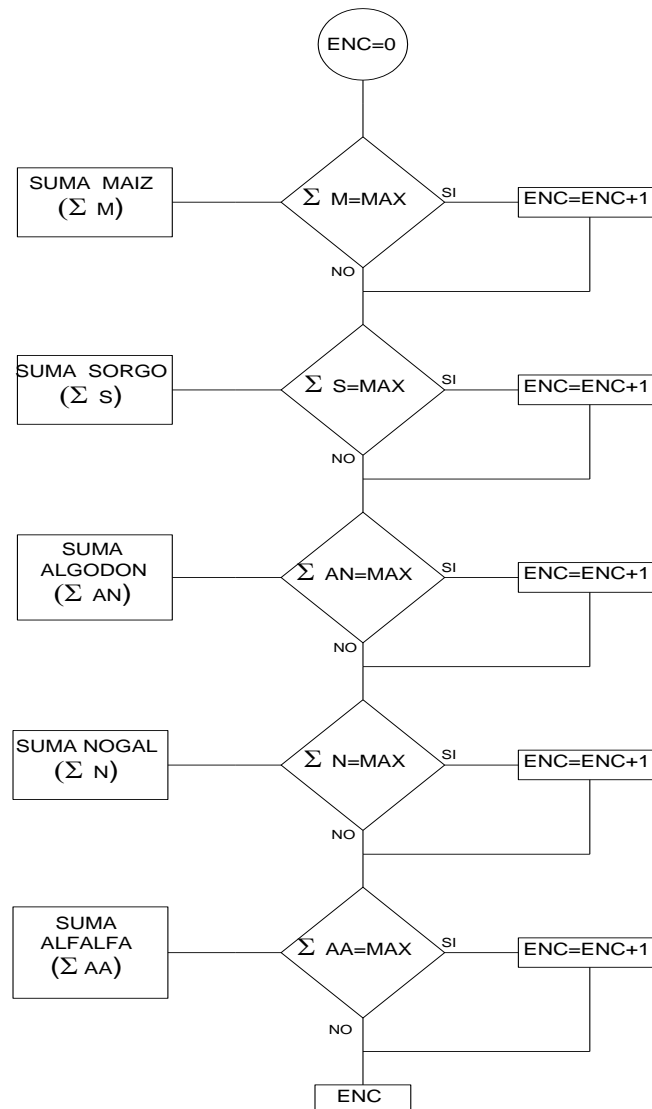


Figura 28. Etapa 4 del clasificador.

Quinta etapa

En la quinta etapa se clasifica el cultivo tomando como consideración el cultivo que tuvo la suma máxima, si dos cultivos o más tuvieron la misma cantidad en la suma máxima se elige el cultivo que más se acerque a las reflectancias de la banda 2 y la banda 3. El diagrama se puede observar en la Figura 29.

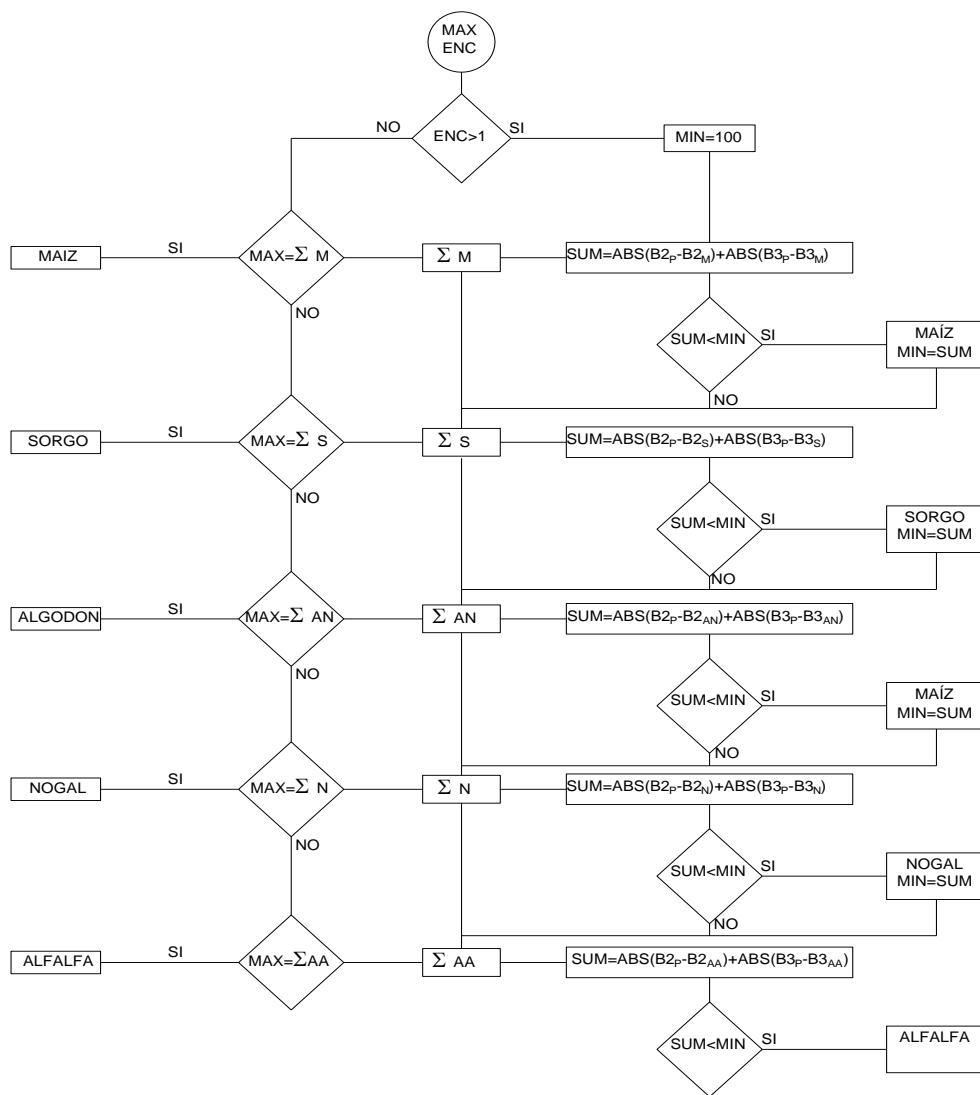


Figura 29. Etapa 5 del clasificador

5. RESULTADOS Y DISCUSIÓN

5.1. Comportamiento por cultivo

Las gráficas resultantes de cada cultivo se muestran a continuación, en un inicio se muestran de un solo cultivo y posteriormente del promedio de todos los cultivos, con el fin de no saturar la vista de la gráfica (Figura 30) se muestran solo una firma por mes.

5.1.1 ALFALFA




Figura 30. Firmas espectrales de la alfalfa

Como se puede observar en el gráfico no se aprecia alguna tendencia en el comportamiento de la firma espectral, sin embargo en todos los meses existe cultivo debido a que las firmas espectrales están alejadas de la firma espectral de un suelo desnudo.

Con el grafico del comportamiento del WdVI (Figura 31) se puede explicar porque no hay tendencias en las firmas espectrales, pues existen tanto incrementos como disminuciones en poco tiempo de la cobertura vegetal. Esto se puede atribuir a los cortes que se dan durante el ciclo.




Figura 31. Comportamiento del WdVI a lo largo del ciclo de una parcela de alfalfa

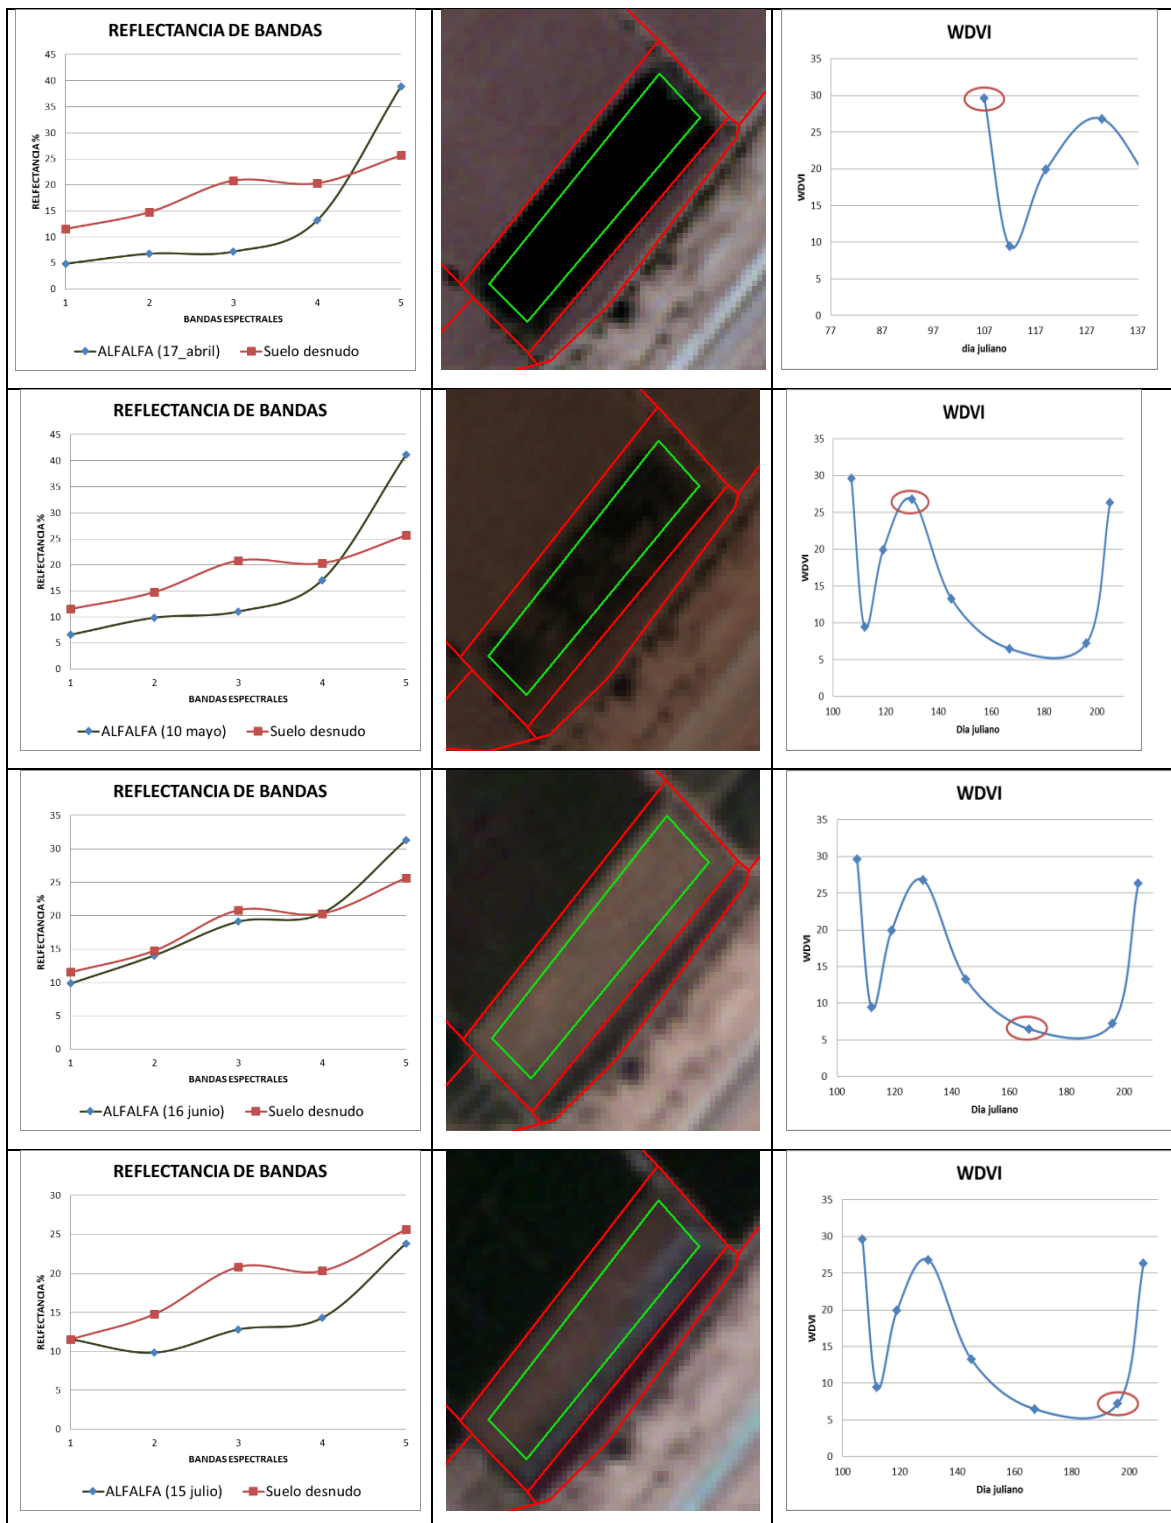


Figura 32. Seguimiento de la parcela de alfalfa.

De la figura anterior (Figura 32) se puede observar de manera muy importante, que aun cuando el WdVI sea el mismo (o en este caso con una diferencia menor a la unidad) las firmas espectrales serán muy diferentes. Como puede verse esto se debe a la influencia del suelo pues son valores muy bajos en donde la cobertura vegetal es menor al 20 %.

5.1.2 ALGODÓN

Las firmas espectrales del algodón (Figura 33) muestran un comportamiento o tendencia de disminuir la reflectancia de las bandas 3 (roja) y la banda 4 (borde rojo) y de aumentar la banda 5 (infrarrojo cercano). El comportamiento del WdVI se observa en la Figura 34.




Figura 33. Firmas espectrales del algodón.




Figura 34. Comportamiento del WDVl a lo largo del ciclo de una parcela de algod3n.

El comportamiento que sigue es ascendente por lo que en la Figura 35 se muestra como son las firmas espectrales una vez que el WDVl es mayor a 2. Como puede verse las firmas cambian con el tiempo y al final no parecen estabilizarse para adoptar una forma definida. Del mismo modo la firma espectral del 15 de julio deber3a situarse entre la firma del 16 de junio y 24 de julio sin embargo se sitúa por debajo de todas.




Figura 35. Firmas espectrales del algod3n a WDVl superior a 5

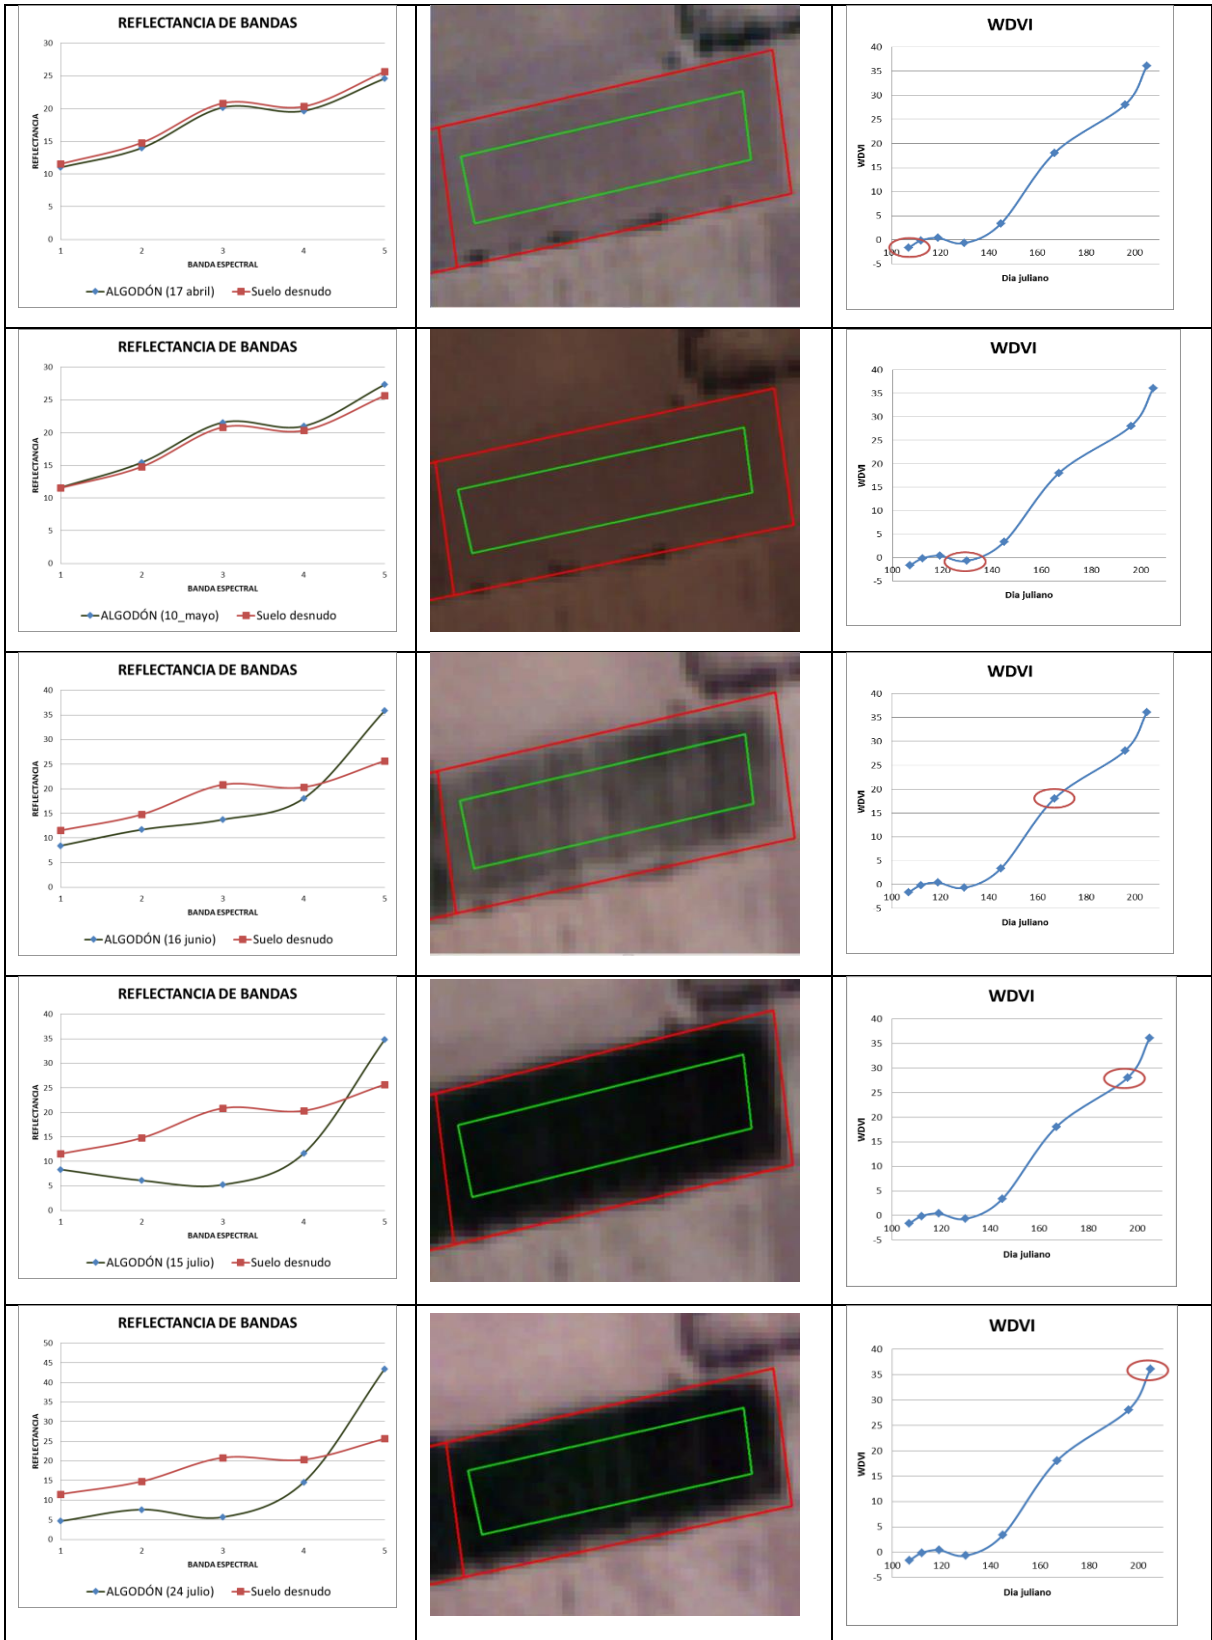


Figura 36. Seguimiento de la parcela de algodón.

5.1.3 MAIZ

En el caso del maíz se puede observar igualmente un patrón de cambio de la firma espectral a lo largo del ciclo. De manera similar al algodón la reflectancia de la banda azul de la toma del 15 de julio no concuerda con el comportamiento del resto de las bandas; esto se debe que al momento de realizar la corrección atmosférica se encontró que el pixel con menor reflectancia en la banda azul fue de 3 por lo que se le restó solo una unidad mientras que para el resto de las imágenes cercanas a esa fecha en promedio se restaba 6 unidades. Esto ocasionó que no se pudiera considerar a la banda azul como parámetro de clasificación ya que es evidente que el método de corrección atmosférica no resultó útil para esta imagen en particular (ver Figura 37).




Figura 37. Firmas espectrales del maíz.

Como se puede observar en la Figura 38 las ocho tomas alcanzaron a cubrir el ciclo vegetativo del maíz para esta parcela.




Figura 38. Comportamiento del WDVI a lo largo del ciclo de una parcela de maíz.

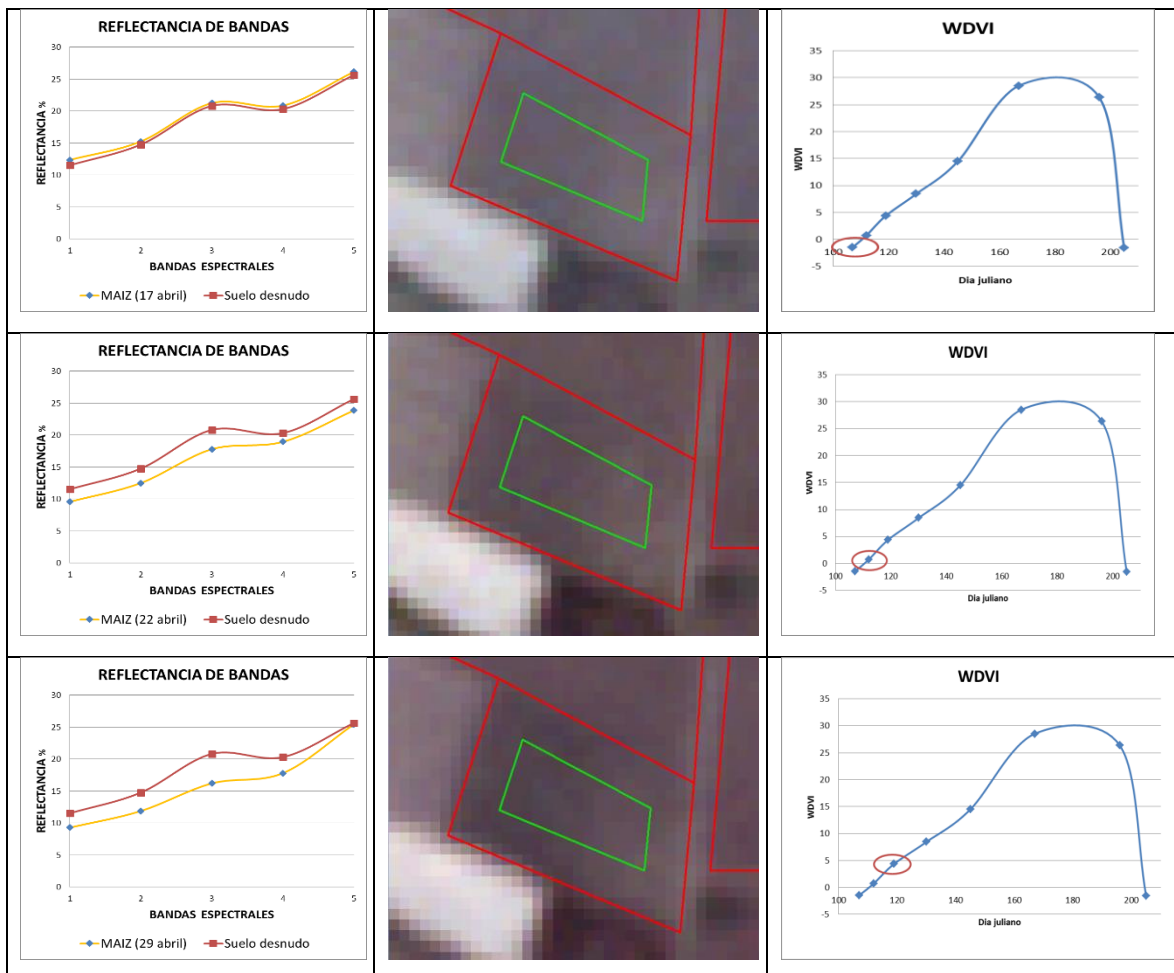


Figura 39. Comportamiento del WDVI a lo largo del ciclo de una parcela de maíz (abril 2013).

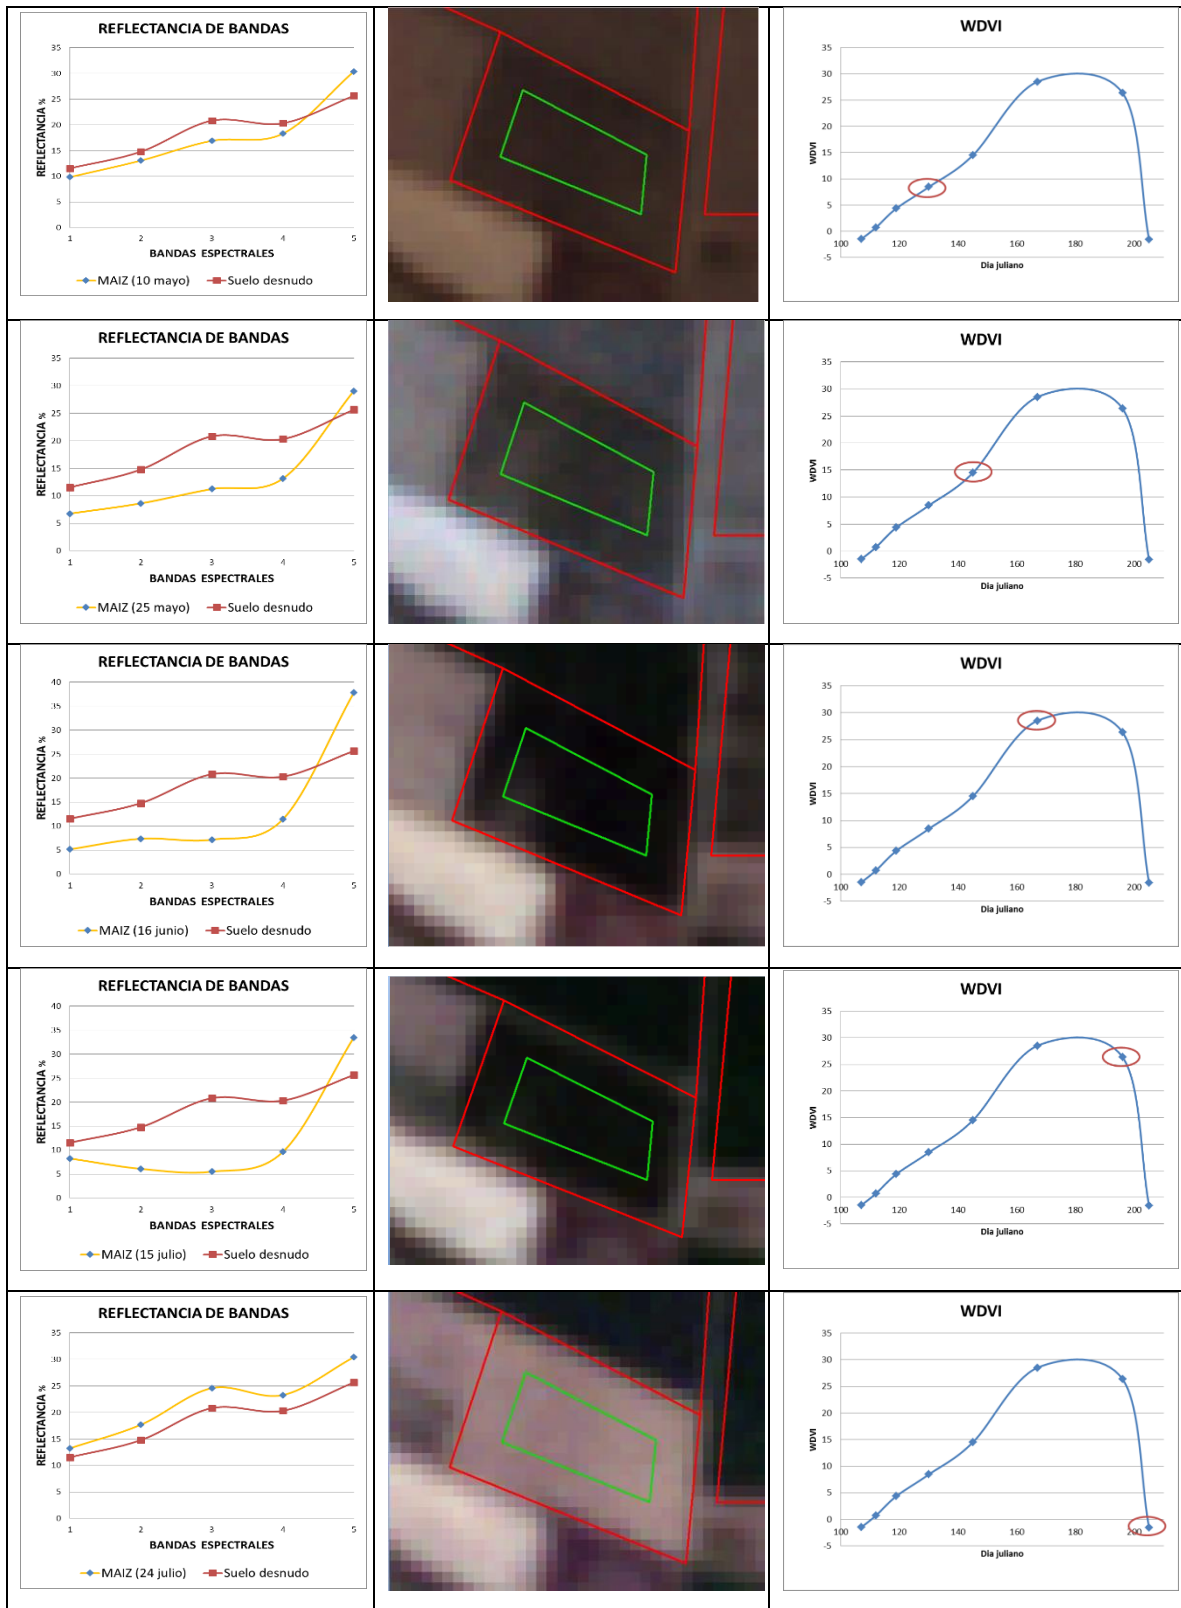


Figura 40. Comportamiento del WDV a lo largo del ciclo de una parcela de maíz (mayo-julio 2013).

Tomando de ejemplo la parcela de maíz se puede notar lo siguiente:

La firma del maíz sigue un patrón como el que se sabe y espera que tengan todos los cultivos un aumento de la reflectancia de la banda del infrarrojo cercano y una disminución de la roja sin embargo el aumento o disminución de las reflectancias no es proporcional, como se puede ver en la Figura 41 la banda roja siempre disminuye conforme avanza el tiempo es decir la banda roja refleja menos que la toma anterior. Sin embargo no ocurre lo mismo en la banda del infrarrojo ya que en ocasiones la reflectancia es menor a la reflectancia anterior; este comportamiento se ve al comparar la reflectancia del 10 de mayo y 25 de mayo. Esta discordancia también podría atribuírsele a errores en la corrección atmosférica, pero en general todos los cultivos analizados presentan este comportamiento.




Figura 41. Firmas espectrales del maíz a WdVI superior a 4

5.1.4 NOGAL

Para mostrar el análisis de las parcelas de nogal se muestran dos ejemplos. Se encontró una variación en cuanto al valor del WDVl y los valores de reflectancia que alcanzan el infrarrojo cercano.

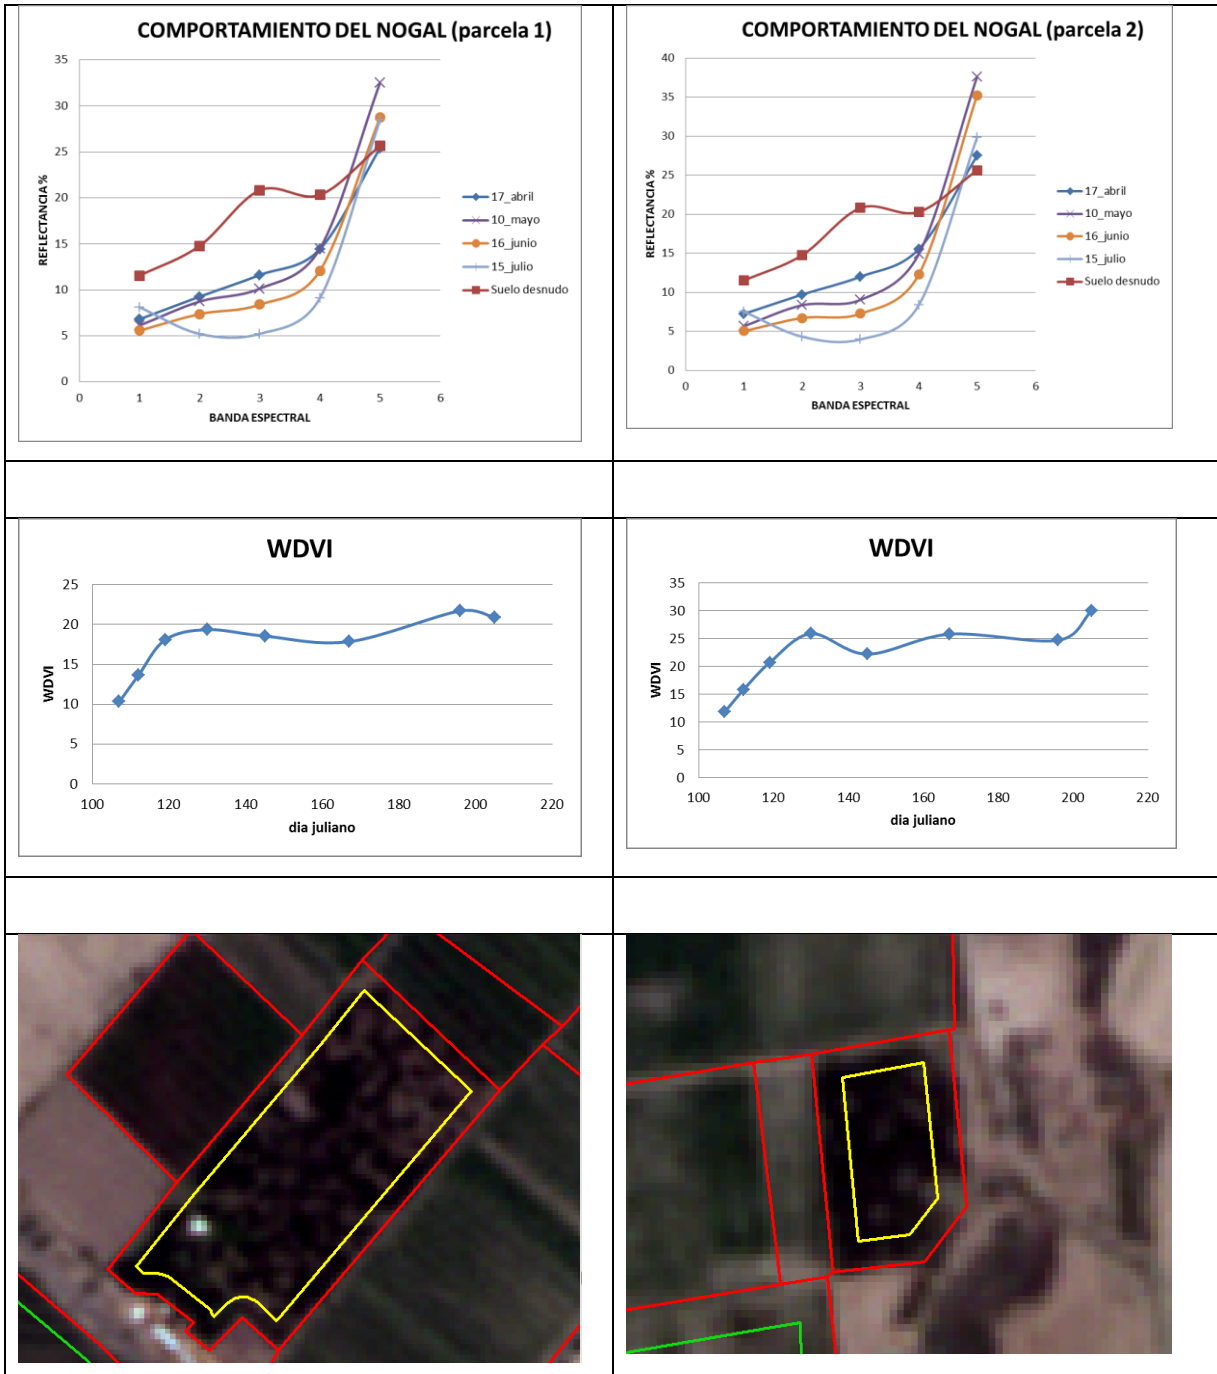


Figura 42. Comparación de firmas de parcelas del nogal

Con base en la Figura 42 y considerando que se trata de una parcela con un cultivo perenne, donde el porcentaje de cubierta vegetal no cambia, como se nota en los valores de WdVI a partir del día juliano 130 se puede deducir lo siguiente:

- El WdVI mide indirectamente el porcentaje de cubierta vegetal, con ayuda de la imagen de satélite puede notarse que la plantación de la parcela 1 es menos densa que la de la parcela 2 por ello que el WdVI parece estabilizarse.
- Aun cuando el WdVI es distinto, las firmas espectrales son muy parecidas especialmente la banda 4 en donde la diferencia de la reflectancia es menor a 1.7 (Cuadro 8, en azul se muestran los valores que están graficados).
- La banda cuatro sería un buen indicador que minimiza los efectos del suelo para comparar dos mismos cultivos.

Cuadro 8. Comparación de valores de la banda 4 de parcelas de nogal (P1: Parcela 1, P2: Parcela 2, DIF: DIFERENCIA ABS: ABSOLUTA)

Día juliano	WdVI (P1)	B4 (P1)	WdVI (P2)	B4 (P2)	DIFERENCIA WdVI ABS(P2- P1)	DIFERENCIA B4 ABS(P2-P1)
107	10.31	14.42	11.88	15.56	1.58	1.1
112	13.62	13.22	15.86	14.52	2.23	1.3
119	18.08	12.75	20.72	12.11	2.63	0.6
130	19.35	14.48	25.88	14.93	6.53	0.4
145	18.55	12.61	22.22	10.92	3.68	1.7
167	17.84	12.07	25.81	12.31	7.97	0.2
196	21.70	9.09	24.71	8.39	3.00	0.7
205	20.89	12.10	30.01	10.76	9.12	1.3

5.1.5 SORGO

Para el cultivo del sorgo se encontró el comportamiento en las firmas espectrales mostrado en la Figura 43 y el WDMI mostrado en la Figura 44.




Figura 43. Firmas espectrales del sorgo




Figura 44. Comportamiento del WDMI a lo largo del ciclo de una parcela de sorgo

El comportamiento del sorgo es muy similar al del maíz y el algodón, al igual que el algodón en la mayoría de las parcelas no se alcanza a notar o abarcar el ciclo completo del sorgo, es debido a esto que se puede apreciar que en ningún momento el WdVI disminuye mostrando la etapa de senescencia del cultivo. Se encontró que generalmente el WdVI de las parcelas de sorgo es mayor que la del maíz, tendiendo (en general) a alcanzar un WdVI cerca de los 40. Por el contrario el maíz apenas supera los 30 en la mayoría de las parcelas.

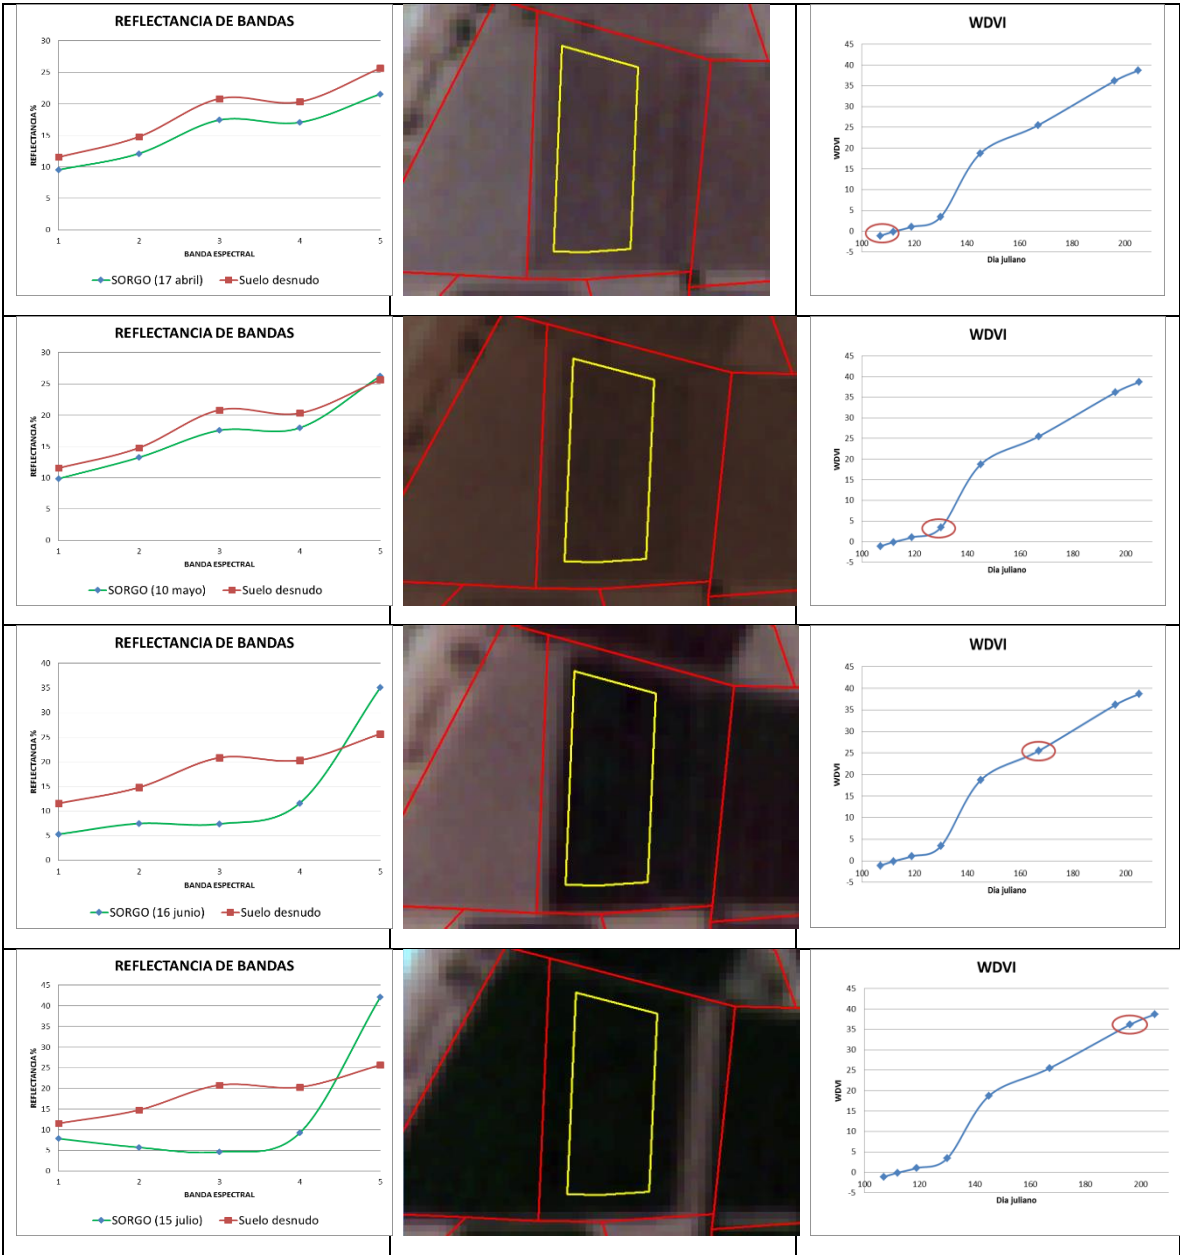


Figura 45. Seguimiento de la parcela de sorgo.

El maíz y el sorgo son cultivos muy parecidos, ambos son gramíneas y visualmente o con ayuda de la imagen es muy difícil distinguirlos sin embargo se encontraron algunas diferencias que se discutirán más adelante.

5.2. Comparación entre cultivos

Se graficó el comportamiento de los cinco cultivos tomando como referencia el WdVI y se notó la clara diferencia entre los cultivos perennes (alfalfa y nogal) de los cultivos anuales (algodón, maíz y sorgo). En los cultivos anuales las líneas se encuentran desplazadas a la izquierda o derecha ya que va a depender de la fecha de siembra, sin embargo se puede notar como el sorgo y el algodón alcanzan mayores valores de WdVI (Figura 46).




Figura 46 Comportamiento de los cinco cultivos

Tomando como referencia la Figura 46 se compararon las firmas espectrales para valores de WdVI entre los 25 y 30 (Figura 47), se observó que existen diferencias entre ellas aunque siguen un mismo patrón.




Figura 47. Comparación de firmas espectrales de los cinco cultivos

5.3. Comparaciones multi-parcelas

Anteriormente se observó gráfica y visualmente el comportamiento de parcelas de los cinco cultivos analizados, sin embargo este comportamiento no es uniforme para todas las parcelas del mismo cultivo y como se discutió al analizar las firmas individualmente no hay una forma clara de ordenar las firmas para su comparación. El WDVl mide indirectamente el porcentaje de cubierta vegetal y por ende podría ser el mejor punto de comparación de firmas entre los diferentes cultivos, a pesar de ello se notó que a iguales valores de WDVl las firmas en el mismo cultivo son distintas, por lo que habría de esperarse a un más error entre cultivos distintos. Prueba de esto se muestran de la Figura 48 a Figura 51.

Se puede notar que aun cuando es el mismo patrón las reflectancias varían, también se puede observar tanto para la parcela 1 como la parcela 2 que existirá un punto en el que el WdVI es muy parecido (día juliano 145 y 196) pero la etapa fenológica es distinta. Las firmas espectrales para la parcela 2 y 3 se muestran en la Figura 50.

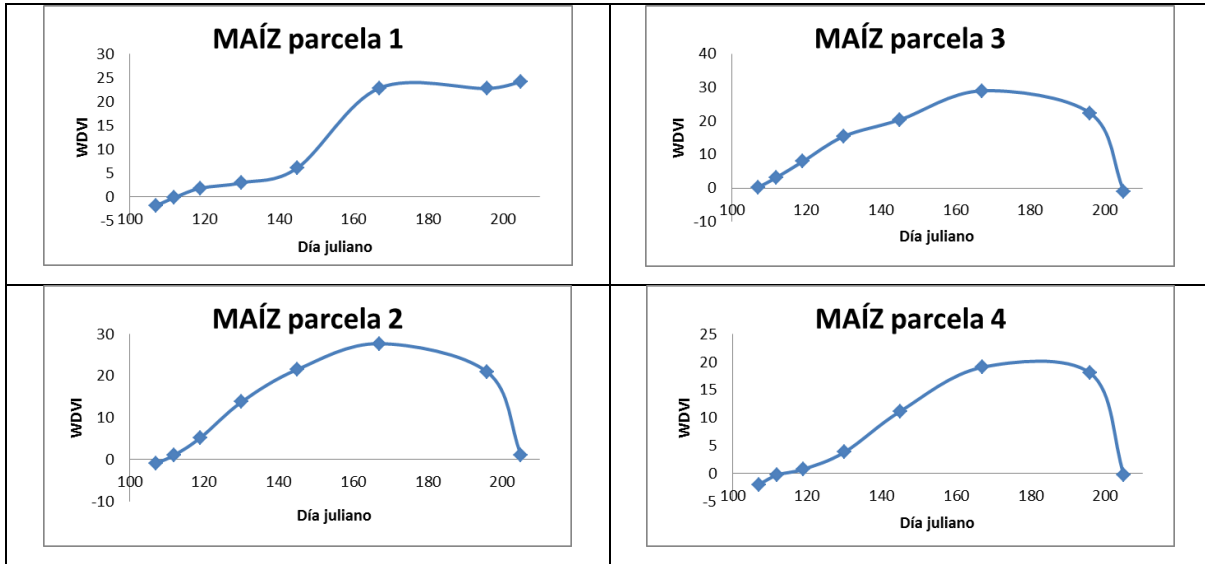


Figura 48. Comportamiento del WdVI en cuatro parcelas




Figura 49. Comparación parcelas de maíz




Figura 50. Comparación de firmas en fase de crecimiento y senescencia.

En ambas gráficas se observa que a pesar de que el WdVI es similar (con una diferencia menor 2 en caso de la parcela 3 y menor a 1 en caso de la parcela 2), se sigue una tendencia en la firma espectral cuando el cultivo está en la fase de senescencia, la firma se encuentra desplazada hacia abajo (este comportamiento se observó para la mayoría de las parcelas).

Lo anterior nos llevó a inferir que existe una relación directa con la fase fenológica del cultivo en el tiempo comparando **las banda 2 y la banda 4**, también con la banda 3 y 5 pero éstas (como se demostró en análisis anteriores) pueden no seguir un patrón.

La Figura 51 muestra las diferencias de las bandas espectrales comparando parcelas diferentes. Se tuvo la precaución de comparar firmas de cultivos únicamente de la fase de crecimiento.




Figura 51. Diferencias espectrales a mismos valores de WdVI en maíz

Se puede ver que existen diferencia entre los valores de reflectancia de hasta 4 unidades en las bandas 2, 3 y 4 siendo que la máxima diferencia entre un suelo desnudo y con cultivo en su máximo crecimiento es de 9 unidades en promedio, aun cuando las diferencias se vuelven menores a medida que el WdVI aumenta, podemos decir que usar el WdVI como punto de partida para clasificar firmas arrojaría mucho error.

5.4. Análisis individual de las bandas espectrales a lo largo del ciclo.

Comparar valores a través del tiempo en el ciclo del cultivo no fue del todo correcto pues como se dijo anteriormente los valores de reflectancia son alterados con una relativa facilidad si el método de corrección atmosférica no es aplicado de manera correcta o presenta errores, pero aun así se pudieron observar las siguientes tendencias. Tomando como ejemplo las parcelas de maíz y descartando las fases de senescencia del cultivo se encontró lo siguiente que es mostrado en la Figura 52. Se descarta el análisis de la banda 1 (azul) porque se demostró que existe un error en la aplicación de la corrección atmosférica y la banda 5 porque a pesar de tener una relación directa los valores no reflejan la etapa fenológica del cultivo.




Figura 52. Evolución de los valores de reflectancia.

Como se puede apreciar la banda roja (3) y la banda de borde rojo (4) son las que mejor relación tienen ya que presentan el R^2 mayor, sin embargo los valores de reflectancia de la banda roja son más amplios comparados con los valores de la banda 2 y la banda 4. **Por lo que la banda 4 es la que mejor describe el comportamiento del maíz a lo largo de su ciclo vegetativo.**

Como se puede observar en la Figura 53 la banda 2 es una copia del comportamiento de la banda 4 solo que desplazada hacia abajo, graficando una contra otra se encontró también la siguiente relación para los cinco cultivos analizados.




Figura 53. Relación entre la banda 4 y la banda 2 del maíz

Este mismo análisis se hizo para todas las parcelas de maíz y para todos los cultivos obteniéndose resultados similares siendo la banda 4 la que mejor ajuste tiene comparado con el resto de las bandas.

Como la banda 4 es la que mejor describe el comportamiento del cultivo minimizando el efecto del porcentaje de cubierta vegetal y es también la que mejor describe el comportamiento a través del tiempo, se utilizó la banda 4 como punto de partida para elaborar el clasificador.

5.5. Elaboración del clasificador

Partiendo de que es posible encontrar dos firmas espectrales muy similares pero que se tratan de diferentes cultivos se procedió a comparar firmas para encontrar relaciones entre ellas siempre que el WDV de la parcela fuera mayor a 20. Así mismo en las tres gráficas de cada figura se comparan únicamente firmas en las cuales el valor de la banda 4 (borde rojo) es igual o la diferencia es menor a 0.5 en los valores de reflectancia.

5.5.1 Comparación espectral maíz-sorgo

- Si es MAIZ la banda 3 es mayor a la banda 3 del sorgo
- Si es SORGO la banda 3 es menor que la banda 3 del maíz




Figura 54. Comparación maíz-sorgo

5.5.2 Comparación espectral sorgo-alfalfa

- Si es SORGO la banda 2 es mayor a la banda 2 de la alfalfa.
- Si es ALFALFA la banda 2 es menor a la banda 2 del sorgo.




Figura 55. Comparación sorgo-alfalfa.

5.5.3 Comparación espectral sorgo-nogal

- Si es SORGO la banda 2 es mayor a la banda 2 del nogal.
- Si es NOGAL la banda 2 es menor que la banda 2 del sorgo.




Figura 56. Comparación sorgo-nogal

5.5.4 Comparación espectral sorgo-algodón

- Si es ALGODÓN la banda 2 y 3 será menor que la banda 2 y 3 del sorgo.
- Si es SORGO la banda 2 y 3 será mayor que la banda 2 y 3 del algodón.




Figura 57. Comparación sorgo-algodón.

5.5.5 Comparación espectral maíz-nogal

Siempre que el WDVl sea mayor a 20.

- Si es nogal la banda 2 es menor que la banda 2 del maíz.
- Si es maíz la banda 2 es mayor a la banda 2 del nogal.




Figura 58. Comparación maíz-nogal

5.5.6 Comparación espectral nogal-algodón.

- Si es ALGODÓN la banda 3 será menor que la banda 3 del nogal.
- Si es NOGAL la banda 3 será mayor que la banda 3 del algodón.




Figura 59. Comparación nogal-algodón

5.5.7 Comparación espectral nogal-alfalfa

De 14 casos comparados en 13 se cumplió lo siguiente:

- Si es ALFALFA la banda 3 es menor a la banda3 del nogal
- Si es NOGAL la banda 3 es mayor a la banda 3 de la alfalfa

El caso que no se cumplió se observa en la tercer grafica de la Figura 60.

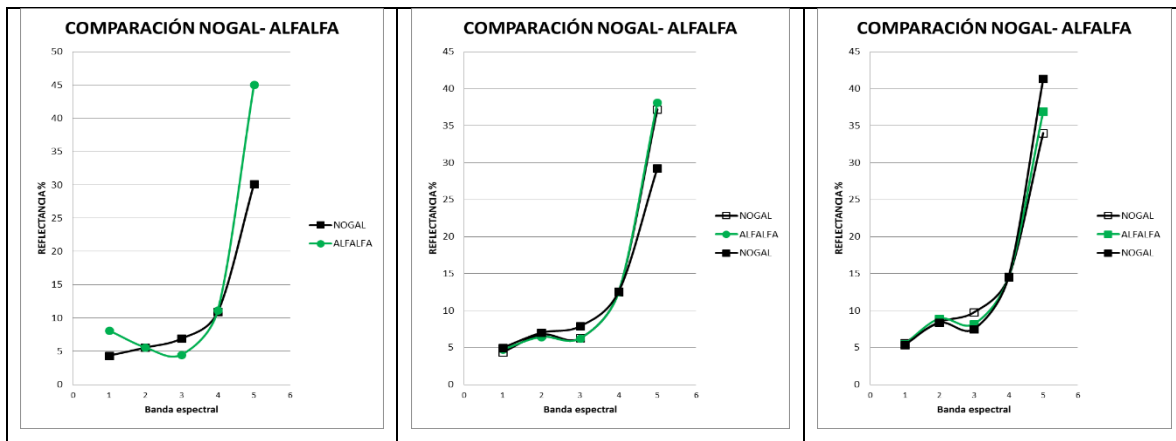


Figura 60. Comparación nogal-alfalfa

5.5.8 Comparación espectral maíz algodón

- Si es ALGODÓN la banda 3 es menor que la banda 3 del maíz.
- Si es MAIZ la banda 3 es mayor que la banda 3 del algodón.




Figura 61. Comparación maíz- algodón.

5.5.9 Comparación espectral maíz alfalfa

- Si es ALFALFA la banda 2 siempre será menor que la banda 2 del maíz.
- Si es MAÍZ la banda 2 siempre será mayor que la banda 2 de la alfalfa.




Figura 62. Comparación maíz- alfalfa.

5.5.10 Comparación espectral alfalfa-algodón

Aun cuando en la mayoría de los casos se encontró que la banda 3 del algodón es menor a la banda 3 de la alfalfa (15 de 18) no se encontró una relación que pudiera discriminar entre estos dos cultivos.




Figura 63. Comparación alfalfa- algodón.

En nueve de los diez casos se encontró que es posible discriminar entre dos cultivos, las comparaciones van entre valores de reflectancia de 10 a 15 (borde rojo) en la mayoría de los casos, pero se debe señalar que no todos los cultivos tuvieron valores entre estos dos números, como se puede observar en la Figura 64.

Por ejemplo en el maíz se llegaron a encontrar valores entre 7.83 % y 15.34 % mientras que en la alfalfa los valores fueron de 10.38 % a 17.27 % (ver Anexos).




Figura 64. Reflectancia de la banda 4 de todos los cultivos

Es importante reiterar que en los límites superiores e inferiores solo se compararon firmas de cultivos con valores cercanos que no superaron media unidad.

Después de tomar estas consideraciones se obtuvo el banco de firmas en los que los cultivos tuvieron un WDWI superior a 20 (ver Anexos), teniendo las siguientes firmas (Cuadro 9).

Cuadro 9. Número de firmas obtenidas por cultivo.

CULTIVO	No de firmas
SORGO	54
MAIZ	43
NOGAL	33
ALFALFA	33
ALGODÓN	20

Este algoritmo se introdujo dentro del algoritmo de clasificación y se validó con todas las parcelas que fueron supervisadas, la imagen de la que se tomaron los datos para asignarlos al vector de parcelas fue la de julio por ser la imagen en donde la mayoría de las parcelas tienen el WdVI mayor a 20 necesario para que pueda ser clasificado. Los resultados se muestran en una matriz de confusión.

5.6. Matriz de confusión

La matriz de confusión obtenida se muestra en el Cuadro 10

Cuadro 10. Matriz de confusión de la clasificación.

		DATOS DE REFERENCIA (PARCELA MUESTREADAS)					TOTAL
		MAIZ	SORGO	ALFALFA	NOGAL	ALGODON	
PARCELAS CLASIFICADAS	MAIZ	81	63	1	1	0	146
	SORGO	22	282	0	1	1	306
	ALFALFA	4	15	2	0	4	25
	NOGAL	12	19	3	4	1	39
	ALGODÓN	1	17	2	1	8	29
	TOTAL	120	396	8	7	14	545

PRECISIÓN DEL PRODUCTOR

MAIZ: $81/120 = 67.5 \%$
 SORGO: $282/396 = 71.26 \%$
 ALFALFA: $2/8 = 25.00 \%$
 NOGAL: $4/7 = 57.14 \%$
 ALGODÓN: $8/14 = 57.14 \%$

PRECISIÓN DEL USUARIO

MAIZ: $81/146 = 55.48$
 SORGO: $282/306 = 92.16$
 ALFALFA: $2/25 = 8.00$
 NOGAL: $4/39 = 10.26$
 ALGODÓN: $8/29 = 27.59$

$$\text{PRECISION GLOBAL} = (81+282+2+4+8)/545=69.17\%$$

Como se puede ver la eficiencia global es muy baja. De acuerdo a la precisión del productor la alfalfa fue que menor asignación correcta tuvo con un 25% y por el contrario el sorgo fue el que más aciertos tuvo con un 71.21%. Tomando en cuenta

la precisión del usuario el sorgo es el que más confiabilidad tiene con un 92.16 %, mientras que la alfalfa resultó el menos confiable con tan solo el 8%.

5.6.1. Índice Kappa

El índice Kappa obtenido en la investigación, de acuerdo a la matriz de confusión generada fue el siguiente:

Los coeficientes obtenidos fueron los siguientes:

P_0 = Proporción de acuerdos observados

$$\frac{81 + 282 + 2 + 4 + 8}{545} = 0.69$$

P_e = Proporción de acuerdos esperados

$$\frac{81}{146} \times \frac{81}{120} + \frac{282}{306} \times \frac{282}{396} + \frac{2}{25} \times \frac{2}{8} + \frac{4}{39} \times \frac{4}{7} + \frac{8}{29} \times \frac{8}{16} = 0.47$$

Por lo que la ecuación resultante sustituyendo en (3) fue:

$$K = \frac{0.69 - 0.47}{1 - 0.47} = 0.42$$

El resultado obtenido muestra una fuerza de concordancia *Moderada* dentro del análisis realizado.

5.7. Mosaico de cultivos

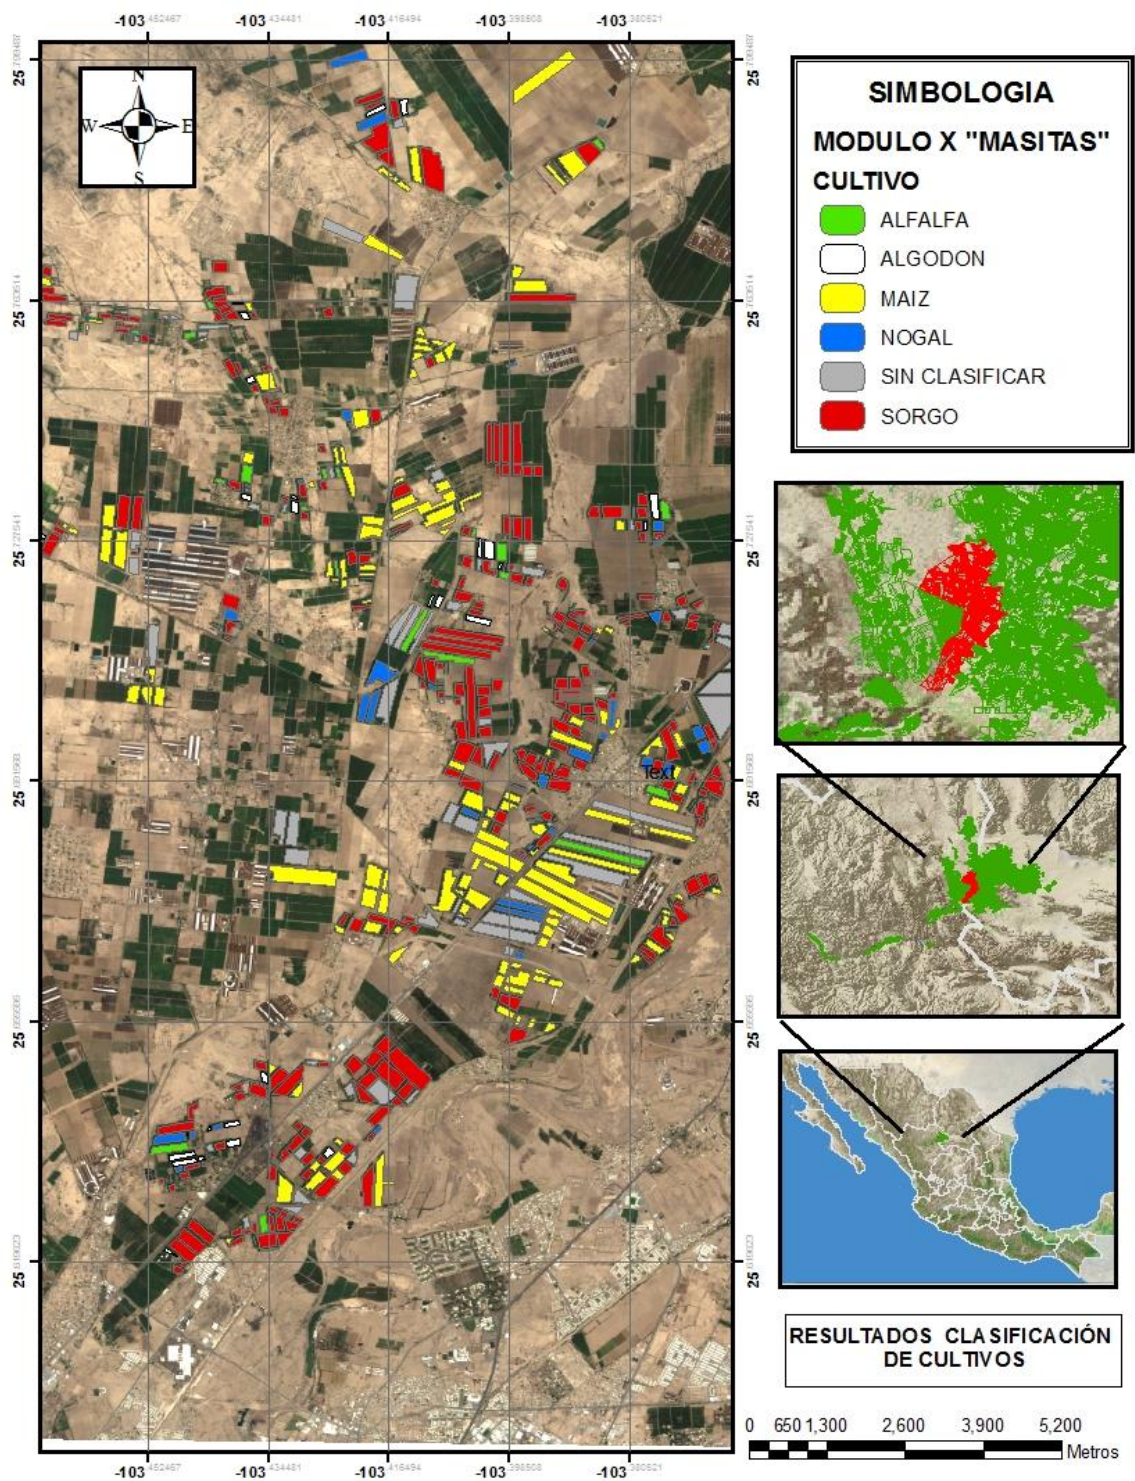


Figura 65. Mosaico de cultivos obtenidos en la clasificación

6. CONCLUSIONES Y RECOMENDACIONES

En el trabajo de investigación se encontró lo siguiente: no es posible asignar a un cultivo una firma espectral única utilizando las reflectancias detectadas por un satélite sobre una parcela, ya que ésta cambia a lo largo de su ciclo vegetativo.

La firma espectral es muy afectada por la influencia del suelo por lo que para poder comparar firmas es necesario que el cultivo cubra más del 50% del suelo con vegetación, esto es cuando el WDVl es superior a 20.

La banda 4 (borde rojo) del satélite RapidEye es la banda que mejor describe la evolución del cultivo y la que menor variación tiene a lo largo de su ciclo vegetativo.

La banda 4 (borde rojo) y la banda 2 (verde) del satélite RapidEye son las que mejor correlación tienen entre sí, esto debido a que la banda 4 es un indicador del contenido de clorofila y nitrógeno, lo que se refleja en una mayor reflectancia del verde en los cultivos.

Aun cuando las firmas espectrales pueden llegar a ser muy parecidas, es posible encontrar diferencias en los valores de reflectancia principalmente de la banda 2 (verde) y 3 (roja) tomando como base un valor en este caso la banda 4.

Los cultivos perennes son en los que mayores diferencias se encontraron en su firma espectral detectada por un satélite pues va a depender de varios parámetros como son el marco de plantación en el caso del nogal y los cortes como ejemplo la alfalfa.

La precisión del clasificador fue muy baja siendo los cultivos perennes los que menor índice de clasificación tuvieron y los que más se confundieron con los demás cultivos. Por el contrario el maíz y el sorgo son los que mayor índice de clasificación tuvieron y se pudieron diferenciar entre sí.

Al realizar comparaciones de imágenes de distintas fechas es importante realizar correctamente la corrección atmosférica, se podrían utilizar más de una técnica para obtener resultados más confiables.

La mayor precisión del clasificador fue en los cultivos que tuvieron más firmas sobre las cuales compararse, la precisión pudiera aumentar para los demás cultivos si hubiera una mayor cantidad de firmas sobre las cuales comparar.

Si al clasificador se le aumentara el número de cultivos sobre los cuales comparar se tendrían más elementos para discriminar cultivos.

Se recomienda también tener bancos de firmas distintos para un mismo cultivo es decir no solo tener un banco de firmas para el maíz, si no en base a comportamientos observados en las imágenes tener maíz tipo1, maíz tipo2 ... maíz tipo n.

7. LITERATURA CITADA

- Abraira V. 2001. *El índice Kappa*. SEMERGEN; 27: 247-249.
Documento disponible en:
ftp://ftp.hrc.es/pub/bioest/diag/kappa_semergen.pdf
Fecha de consulta: 05-Abril-2014
- Alperin M., I., V.G. Borges, y R. Sarandón. 2002. *Caracterización espacial de los tipos de cobertura de suelo usando técnicas geoestadísticas a partir de información satelital*. Rev. Fac. Agron 105(1): 40-51.
- Arango G., M., Branch B. J. W., y Botero F. V. 2005. *Clasificación no supervisada de coberturas vegetales sobre imágenes digitales de sensores remotos: "landsat – etm+"*. Revista Facultad nacional de Agronomía Medellín. 58 (1): 2611-2634
Documento disponible en:
<http://www.revistas.unal.edu.co/index.php/refame/article/download/21276/22251>.
Fecha de consulta: 15-abril-2014
- Bindel M., Hese Sören., C. Berger, and Schmuilius C. 2011. *Evaluation of red-edge spectral information for biotope mapping using RapidEye*. In: Proc. SPIE 8174, Remote Sensing for Agriculture, Ecosystems, and Hydrology XIII, 81740X (October, 2011). International Society for Optics and Photonics: 817400X - 817400X-9.
- Blackbridge. 2013. *Imágenes Satelitales Especificaciones Técnicas*.
Documento disponible en:
http://www.blackbridge.com/rapideye/upload/RE_Product_Specifications_SPA.pdf
Fecha de consulta: 5-Abril-2014

- Blaschke T. 2010. *Object based image analysis for remote sensing*. ISPRS Journal of Photogrammetry and Remote Sensing 65: 2–16.
- Blaschke, T., Hay G,J., Kelly, M., Lang, S., Hofmann, P., Addink E., Queiroz. F R., Van der Meer F.,Van der Weerff.,Van Coillie F., and Tiede,D. 2014. *Geographic Object-Based Image Analysis – Towards a new paradigm*. ISPRS Journal of Photogrammetry and Remote Sensing 87: 180–191.
- Bosque, S. J., Escobar F, J., García, E. y Salado G, M. J. 1994. *Sistemas de Información Geográfica: Prácticas con PC ARC/INFO e IDRISI*. Editorial RA-MA. 480 p.
- Bosque, S., J., y García R, C. 2000. *El uso de los sistemas de información geográfica en la planificación territorial*. 20: 49-67.
Documento disponible en:
<http://revistas.ucm.es/index.php/AGUC/article/viewFile/AGUC0000110049A/31281>
Fecha de consulta: 27 de abril 2014
- Bouman, B. A. M. Van Kasteren H. W. J., and Uenk D. 1992. *Standard relations to estimate ground cover and LAI of agricultural crops from reflectance measurements*. Eur. J. Agron. 1(4): 249-262.
- Brizuela A., B., Aguirre C, A., y Velasco I., 2007. *Aplicación de métodos de corrección atmosférica de datos Landsat 5 para análisis multitemporal*. Buenos aires, Argentina.
- Burrough P., A. and McDonnell, R. 1998. *Principles of Geographical Information Systems*. Oxford University Press, Oxford, U.K.

- Chavez P., S. 1996. *Image based atmospheric corrections- revisited and improved*. Photogrammetric Engineering and Remote Sensing 62 (9): 1025-1036.
- Chuvieco S., E. 1990. *Fundamentos de teledetección espacial*. Segunda edición. 449p. España.
- Chuvieco, S., E. 2002. *Teledetección ambiental. La observación de la Tierra desde el Espacio*. Ariel Ciencia, Barcelona, España. 586 p.
- Chuvieco, E. y Hantson, S. 2010. *Procesamiento estándar de imágenes Landsat*. Documento técnico de algoritmos a aplicar. Universidad de Alcala, España.
Documento disponible en: http://www.ign.es/PNT/pdf/especificaciones-tecnicas-pnt-medar-landsat_v2-2010.pdf
Fecha de consulta: 15-Abril-2014
- Cole, B., J. McMorrow, and M. Evans. 2014. *Spectral monitoring of moorland plant phenology to identify a temporal window for hyperspectral remote sensing of peatland*. ISPRS Journal of Photogrammetry and Remote Sensing 90: 49–58.
- Congalton, R.G. 2004. *Putting the map back in map accuracy assessment*. Chapter 1. Remote sensing and gis accuracy assessment. 320 pp, edited by Lunetta, R.,S. and Lyon, J., G.
- Congalton, R.G., and Green K. 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices Mapping Science Series. 2da Edición*. CRC Press/Taylor & Francis. 183p.

- Eastman, R. 2006. *Idrisi Andes guide to GIS and image processing*. Worcester, USA. Clark University. 328p.
Documento disponible en:
<http://mingaonline.uach.cl/pdf/bosque/v28n2/art09.pdf>
Fecha de consulta: 28-Abril-2014
- ERDAS IMAGINE ®. 1997. *Tour Guides*.
Documento disponible en:
<http://www.ltrs.uri.edu/teaching/TourGuide.pdf>
Fecha de consulta 5-Abril-2014
- Fernández S., A., J. Recio R., and L.A. Ruíz F. 2003. *Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación*. GeoFocus 3: 143-159.
- George, T., J. Tulip, D. Schulten, M. Krischke, and M. Oxford. 2005. *The RapidEye mission design*. Acta Astronautica 56:213-219.
- Gilabert M., A., González P, J., y García H. J. 1997. *Acerca de los índices de vegetación*. Revista de teledetección.
Documento disponible en:
http://telenet.fa1.cie.uva.es/promotores/revista/revista_08/AET8_4.pdf
Fecha de consulta: 12-Marzo-2014
- Intergraph. *Erdas Imagine 2013, Product and comparisons*.
Documento disponible en:
http://www.hexagongeospatial.com/Libraries/Tech_Docs/ERDAS_IMAGINE_2013_Product_Description.sflb.ashx
Fecha de consulta: 16-Abril-2014

- Jackson R., D., and Huete R, A. 1991. *Interpreting vegetation indices*. Preventive Veterinary Medicine, 11: 185-200.
- Jensen, J R. 2000. *Remote sensing of the environment: an earth resource perspective*. Prentice-Hall, Inc. 541 p.
- Labrador G., M., Évora B. J.A., y Arbelo P., M. 2012. *Satélites de teledetección para la gestión de territorio*. Consejería de Agricultura, Ganadería, Pesca y Aguas del Gobierno de Canarias.66pp.
- Lillesand, T M. R.W. Kiefer and J.W. Chipman. 2004. *Remote sensing and image interpretation*. New York, USA. Wiley. 763 p.
- Lu,D and Weng, Q. 2007. *A survey of image classification methods and techniques for improving classification performance*. International Journal of Remote Sensing, 28:5, 823-870.
- Macedo C., A., Pajares M, G., y Santos P., M. 2010. *Clasificación no supervisada con imágenes a color de cobertura terrestre*. Agrociencia 44: 711-722.
- Macedo C., A. 2012. *Técnicas de clasificación automática de uso de suelos agrícolas y forestales basadas en imágenes digitales*. Dirigido por Santos Peñas y Pajares Martinsanz. Tesis doctoral. Universidad Complutense de Madrid, Facultad de Ciencias Físicas. 229 p.
- *Manual de teledetección. Proyecto de Bosques Nativos y Áreas Protegidas BIRF 4085-AR. 2004*. Inventario Nacional de Bosques Nativos y Sistema Nacional de Evaluación Foresta. Argentina.
Documento disponible en:
http://www.ambiente.gov.ar/archivos/web/UMSEF/File/PINBN/nueva_version_manuales/pinbn_manual_teledeteccion.pdf

Fecha de consulta: 15 de Abril

- Mancebo Q., S., Ortega P. E., Valentín C. A., Martín R. B., y Martín F. L. (2008). *Libro SIG: aprendiendo a manejar los SIG en la gestión ambiental*. 109 pp. Madrid, España.

Documento disponible en:

http://oa.upm.es/1244/1/Mancebo_Quintana_SIG_2008a.pdf

Fecha de consulta: 10- Abril- 2014

- Manjarraez D., C., C. Pinedo A., C.E. Vélez S., y A. Pinedo A. 2007. *Separabilidad espectral de cultivos agrícolas con Imágenes Landsat TM*. *Tecnociencia Chihuahua*. 1(2): 48-56.

- Martín F., Corbera J., Marchan J. F., and Gonzáles A. 2011. *RapidEye and the Rededge band for modelling the vegetation and the recovery of the soil moisture*. *Mapping*.50:10-20.

- Martínez M., J. y Díaz P., A. 2005. *Percepción remota “Fundamentos de teledetección espacial”*. Comisión nacional del Agua. 62pp. México.

Documento disponible:

<http://siga.cna.gob.mx/SIGA/Percepcion/Fundamentos%20de%20teledetecci%C3%B3n%20espacial.PDF>

Fecha de consulta: 20-Diciembre-2013

- Warrens, M J. 2010. *Inequalities between kappa and kappa-like statistics for kxk tables*. *Psychometrika*. 75:176-185.

- Moroni M., E. Lupo, E. Marra, and A. Cedenese. 2013. *Hyperspectral image analysis in environmental monitoring: setup of a new tunable filter platform*. *Procedia Environmental Sciences* 19: 885 – 894.

- Oliveira V., C. A., Mather P., and Aplin P. 2003. *Agricultural crop classification using the spectral-temporal response surface*. In :Anais XI SBSR. Belo Horizonte. Brasil, 5-10 abril, 2003. 255-262 p.
- Palacios V., E. Palacios S., J. E. 2007. *Introducción a los sensores remotos y a los sistemas de información geográfica*. Colegio de Postgraduados, Montecillo, Texcoco, Estado de México. 220 p.
- Palacios V., E., and H. Flores M. 2013. *Crop evapotranspiration estimation through the use of satellite images*. Journal of Earth Science and Engineering 3: 663-671
- Paz P., F., E. Palacios V., M. Martínez M., y L.A. Palacios S. 2005. *Análisis de los espacios espectrales de la reflectividad del follaje de los cultivos*. Agrocienca. 39: 293-301.
- Paz P., F., E. Palacios V., M. Bolaños G., L. A. Palacios S., M. Martínez M., E. Mejía S., A. Huete 2007. *Diseño de un índice espectral de la vegetación: NDVIcp*. Agrocienca 41: 539-554.
- Peña A., M.A. 2007. *Correcciones de una imagen satelital ASTER para estimar parámetros vegetacionales en la cuenca del río Mirta, Aisén*. BOSQUE (Valdivia) 28(2): 162-172. Chile.
Documento disponible en:
http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0717-92002007000200009
Fecha de consulta: 10-marzo-2014
- Perea A., J., J. E. Meroño, y M.J. Aguilera. 2009. *Clasificación orientada a objetos en fotografías aéreas digitales para la discriminación de usos del suelo*. Interciencia 34(9): 612-616.

- Pérez, G. C. y A. L. Muñoz N. 2006. *Teledetección: Nociones y aplicaciones*. Editorial Carlos Pérez.
- Ramírez P., F., F. Paz P., M. Martínez M., E. Palacios V., E. Mejía S., y E. Rubio G. 2010. *Clasificador genérico de objetos en imágenes AVHRR*. Terra Latinoamericana 28 (1): 1-13.
- RapidEye. *Imágenes satelitales de alta resolución*. Documento disponible en:
http://www.geosoluciones.cl/documentos/rapideye/RapidEye_GS.pdf
 Fecha de consulta: 6-Febrero-2014
- Rodríguez M., V.M., M. Tiscareño L., A.D. Báez G., y J. Macías C. 2004. *Identificación de sembradíos de maíz y estimación de su superficie por medio de imágenes Landsat 7 ETM+*. Agricultura Técnica en México 30(001): 29-40.
- Rubio B., A. y J. Gutierrez P., 1997. *Los sistemas de información geográficos: origen y perspectivas*. Revista general de información y documentación. Vol. 7, 1. 93p.
- Salazar R., J.G., L.Tijerilla C., E. Mejía S., M. Sandoval V., P. Sanchez G., H. Vaquera H., y M. T. Colinas L. 2007. *Índices de vegetación para estimar el crecimiento de plantas de tomate (Lycopersicon esculentum Mill.) estresadas por deficiencia de agua y nitrógeno*. Terra Latinoamericana 29:1. 47-56.
- Silleos N., G., K. Alexandridis T., K. Gitas, Z. Gitas L., and K. Peakis (2006). *Vegetation Indexes: Advances Made in Biomass Estimation and Vegetation Monitoring in the last 30 years*. Geocarto International. 21:4. 21-28.

- Sobrino, J.A. 2001. *Teledetección*. Universidad de Valencia. 469 p.
- Vasquez R., M. 2008. *Determinación de superficies cultivadas en terrenos de ladera a partir de imágenes de satélite y ortofotos digitales*. Tesis de Maestría. Colegio de Postgraduados.México.
- Vercher A., A. Gilabert M., F. Camacho D., y J. Meliá. 2002. *Influencia del ángulo cenital de iluminación en los índices de vegetación*. Revista teledetección 18: 75-89.
- Vicente F., R. 2011. *Optimización de la clasificación supervisada basada en objetos aplicada a ambientes rurales a partir de ortoimágenes de geoeye-1*. Tesis de Licenciatura. Escuela Superior de ingeniería Universidad de Almeria.
- Volante N., J., C. Campos J., N. Yanina E., y E. Hernán J. 2007. *Método de Clasificación «Por-parcela» para la Detección de Cultivos: Aplicación al Área Agrícola de Las Lajitas (Salta, Argentina), Campaña Agrícola de Invierno 2006*. In: XII Congreso de la asociación española de teledetección, 19-21 Septiembre, 2007, Mar del Plata, Argentina. Teledetección 79-86.

ANEXOS

ANEXO A. FIRMAS ESPECTRALES

MAÍZ

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
1	MAIZ	7.41	4.68	4.06	7.83	30.95
2	MAIZ	7.76	5.02	4.70	8.33	33.23
3	MAIZ	7.94	5.45	5.26	8.48	30.77
4	MAIZ	7.81	5.30	4.98	8.49	30.07
5	MAIZ	7.99	5.51	5.97	8.68	29.37
6	MAIZ	7.69	5.26	5.05	8.75	31.33
7	MAIZ	8.24	5.82	6.02	8.96	30.07
8	MAIZ	3.89	5.01	5.39	9.11	39.17
9	MAIZ	7.89	5.67	5.30	9.21	33.17
10	MAIZ	8.41	6.01	6.12	9.44	34.77
11	MAIZ	8.00	6.03	5.44	9.55	28.60
12	MAIZ	4.69	5.76	6.82	9.57	30.17
13	MAIZ	8.26	6.09	5.50	9.62	33.50
14	MAIZ	8.18	6.39	6.17	9.88	28.94
15	MAIZ	8.28	6.39	6.24	10.03	30.49
16	MAIZ	8.76	6.75	6.49	10.12	31.19
17	MAIZ	4.05	5.94	5.64	10.13	35.69
18	MAIZ	4.84	6.00	7.26	10.23	31.11
19	MAIZ	4.75	6.20	6.61	10.23	31.09
20	MAIZ	4.63	6.54	6.48	10.25	34.95
21	MAIZ	4.23	6.41	5.92	10.46	33.82
22	MAIZ	5.14	7.28	6.61	10.66	37.47
23	MAIZ	4.93	7.22	7.10	10.82	38.31
24	MAIZ	4.81	6.45	7.25	10.97	30.31
25	MAIZ	4.74	6.96	6.33	10.98	35.64

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
26	MAIZ	5.01	6.64	6.79	11.02	36.86
27	MAIZ	4.98	7.57	7.19	11.16	35.50
28	MAIZ	5.52	7.86	7.70	11.26	36.48
29	MAIZ	5.16	7.37	7.18	11.42	37.83
30	MAIZ	4.98	7.37	7.14	11.46	35.88
31	MAIZ	4.64	6.60	6.14	11.58	44.38
32	MAIZ	5.10	7.58	8.04	11.76	33.57
33	MAIZ	9.04	7.39	7.35	11.82	36.64
34	MAIZ	9.26	7.70	7.84	11.98	34.22
35	MAIZ	5.68	7.49	8.71	12.13	32.90
36	MAIZ	4.64	7.47	6.21	12.15	44.24
37	MAIZ	6.11	8.34	9.21	12.29	33.63
38	MAIZ	4.98	7.69	6.29	12.30	48.80
39	MAIZ	9.92	8.51	8.54	12.45	32.43
40	MAIZ	6.39	8.84	9.19	12.54	35.96
41	MAIZ	5.94	8.49	7.68	12.55	39.03
42	MAIZ	6.35	8.49	8.73	12.72	34.30
43	MAIZ	6.01	8.13	9.16	13.00	32.31
44	MAIZ	5.91	8.46	8.68	13.11	40.11
45	MAIZ	6.20	8.85	9.70	13.14	38.20
46	MAIZ	5.39	8.74	8.39	13.17	32.32
47	MAIZ	5.77	8.74	8.14	13.34	38.32
48	MAIZ	7.21	9.74	9.90	13.54	35.72
49	MAIZ	6.04	9.01	9.26	13.63	36.20
50	MAIZ	6.48	9.32	9.74	13.88	39.78
51	MAIZ	5.91	9.22	9.41	14.72	40.81
52	MAIZ	7.16	10.12	11.24	14.84	37.64
53	MAIZ	6.42	10.44	9.35	15.30	41.91
54	MAIZ	6.46	9.70	10.72	15.34	37.34

SORGO

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
1	SORGO	7.71	5.52	4.19	8.98	40.41
2	SORGO	7.85	5.72	4.59	9.24	42.10
3	SORGO	7.95	5.93	4.70	9.28	39.28
4	SORGO	7.63	5.57	4.05	9.31	42.57
5	SORGO	7.85	5.86	4.32	9.45	39.53
6	SORGO	7.63	5.73	4.29	9.63	39.10
7	SORGO	7.55	5.86	4.10	9.82	42.18
8	SORGO	7.70	5.91	4.46	9.88	40.63
9	SORGO	7.96	6.09	4.50	10.17	41.60
10	SORGO	8.01	6.33	4.55	10.24	42.08
11	SORGO	8.12	6.43	4.85	10.37	40.74
12	SORGO	7.88	6.27	4.41	10.43	41.18
13	SORGO	8.46	6.80	5.26	10.46	37.81
14	SORGO	8.51	6.68	6.01	10.53	37.59
15	SORGO	8.88	7.00	6.27	10.67	34.78
16	SORGO	8.42	6.93	5.65	10.73	34.59
17	SORGO	8.10	6.72	4.91	11.06	41.12
18	SORGO	5.27	7.45	7.36	11.59	35.06
19	SORGO	4.62	7.79	5.89	12.07	48.38
20	SORGO	4.67	7.59	5.87	12.11	47.57
21	SORGO	8.24	7.34	5.27	12.11	44.00
22	SORGO	8.84	7.73	6.44	12.13	33.22
23	SORGO	5.18	8.05	6.10	12.24	47.21
24	SORGO	4.54	7.62	5.67	12.25	51.82

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
25	SORGO	4.74	7.65	6.19	12.25	46.71
26	SORGO	4.63	7.94	5.92	12.40	48.17
27	SORGO	4.92	8.03	5.89	12.41	48.71
28	SORGO	5.01	8.19	6.32	12.54	46.89
29	SORGO	4.62	8.20	5.87	12.63	47.72
30	SORGO	4.77	8.44	5.94	12.69	49.07
31	SORGO	4.77	8.32	5.85	12.85	47.49
32	SORGO	4.69	7.97	7.04	12.91	38.39
33	SORGO	4.41	7.96	5.53	13.01	50.76
34	SORGO	4.48	8.11	5.67	13.03	52.15
35	SORGO	5.27	8.62	7.94	13.22	32.32
36	SORGO	5.20	8.82	6.94	13.50	46.25
37	SORGO	5.25	8.77	7.52	13.62	44.11
38	SORGO	5.48	9.37	7.21	13.93	45.86
39	SORGO	6.42	9.44	10.22	14.10	37.36
40	SORGO	7.20	10.06	10.02	14.11	35.72
41	SORGO	6.43	10.42	8.15	14.74	45.75
42	SORGO	6.69	10.62	8.62	14.99	45.45
43	SORGO	7.03	10.57	10.06	15.73	43.28
44	SORGO	6.76	10.57	10.16	15.83	41.74
45	SORGO	6.20	10.72	8.37	16.02	50.60

ALGODÓN.

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
1	ALGODON	8.06	5.66	4.76	11.12	33.67
2	ALGODON	8.34	6.11	5.23	11.61	34.83
3	ALGODON	7.90	5.65	4.14	12.29	44.77
4	ALGODON	7.13	5.32	3.48	12.49	46.54
5	ALGODON	8.35	6.51	5.58	12.73	35.29
6	ALGODON	8.16	7.00	4.88	13.97	42.91
7	ALGODON	7.47	4.84	4.39	13.99	36.31
8	ALGODON	4.35	6.85	6.06	14.06	39.41
9	ALGODON	4.08	6.43	5.40	14.14	39.67
10	ALGODON	7.91	5.83	4.98	14.22	39.34
11	ALGODON	9.75	8.28	8.16	14.40	37.13
12	ALGODON	3.93	6.75	5.13	14.44	48.99
13	ALGODON	4.66	7.61	5.68	14.56	43.48
14	ALGODON	4.46	7.62	5.69	14.81	43.00
15	ALGODON	4.87	8.00	5.99	15.15	45.08
16	ALGODON	3.81	7.08	4.67	15.42	55.84
17	ALGODON	5.34	8.40	6.76	15.64	44.38
18	ALGODON	4.33	7.37	5.00	15.75	54.41
19	ALGODON	7.39	10.78	11.46	17.04	38.99
20	ALGODON	4.89	8.97	5.84	17.16	52.18

NOGAL

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
1	NOGAL	7.54	4.33	3.99	8.39	29.89
2	NOGAL	7.55	4.65	4.77	8.97	28.80
3	NOGAL	8.10	5.20	5.21	9.09	28.48
4	NOGAL	7.96	5.50	4.35	9.32	42.73
5	NOGAL	7.80	5.60	4.49	10.15	33.35
6	NOGAL	3.98	5.18	5.96	10.45	29.93
7	NOGAL	4.27	5.92	5.20	10.76	36.77
8	NOGAL	4.73	5.77	6.88	10.92	31.17
9	NOGAL	4.35	5.55	6.91	10.92	30.12
10	NOGAL	4.04	6.18	5.49	11.73	34.25
11	NOGAL	4.94	7.40	5.77	11.83	48.81
12	NOGAL	4.10	6.62	5.49	11.97	35.62
13	NOGAL	4.21	6.78	5.68	12.01	34.43
14	NOGAL	5.16	7.43	8.07	12.10	31.38
15	NOGAL	4.66	6.60	6.93	12.11	29.72
16	NOGAL	4.73	6.08	7.68	12.15	32.43
17	NOGAL	4.71	6.67	7.08	12.22	30.76
18	NOGAL	5.04	6.73	7.28	12.31	35.27
19	NOGAL	4.38	6.69	6.40	12.34	36.15
20	NOGAL	4.36	6.77	6.27	12.53	37.21
21	NOGAL	4.80	7.03	7.26	12.63	37.30
22	NOGAL	4.75	7.41	6.25	12.71	38.38
23	NOGAL	4.61	7.10	6.88	12.72	34.59
24	NOGAL	5.24	7.44	8.07	12.88	35.81

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
25	NOGAL	5.00	7.13	7.60	12.90	33.77
26	NOGAL	5.33	7.54	8.79	13.09	32.37
27	NOGAL	5.77	8.13	9.55	13.69	34.32
28	NOGAL	5.65	8.43	9.77	14.52	34.00
29	NOGAL	5.37	8.37	7.52	14.59	41.31
30	NOGAL	5.41	8.21	9.22	14.77	34.44
31	NOGAL	7.34	10.05	10.67	14.77	37.27
32	NOGAL	5.68	8.37	9.06	14.93	37.66
33	NOGAL	5.97	8.99	10.36	15.24	34.98


ALFALFA

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
1	ALFALFA	8.62	6.23	5.87	10.38	27.67
2	ALFALFA	7.75	5.60	4.24	10.60	36.66
3	ALFALFA	7.30	4.37	4.18	10.64	42.35
4	ALFALFA	8.13	5.58	4.50	11.16	45.00
5	ALFALFA	8.68	6.74	6.11	11.58	30.51
6	ALFALFA	3.78	5.43	4.85	11.63	41.81
7	ALFALFA	3.68	5.62	5.33	11.92	33.93
8	ALFALFA	3.56	5.39	4.74	12.04	40.21
9	ALFALFA	4.71	7.57	5.88	12.46	38.46
10	ALFALFA	4.74	6.45	6.25	12.54	38.14
11	ALFALFA	5.21	8.05	7.39	12.98	34.64
12	ALFALFA	4.34	6.77	6.98	13.00	34.99

No	CULTIVO	BANDA AZUL	BANDA VERDE	BANDA ROJA	BANDA BORDE ROJO	BANDA INFRARROJO CERCANO
13	ALFALFA	4.87	6.79	7.19	13.19	38.93
14	ALFALFA	4.50	6.97	5.11	13.26	47.72
15	ALFALFA	4.78	7.30	5.92	13.30	42.46
16	ALFALFA	4.83	6.66	6.37	13.33	45.40
17	ALFALFA	4.34	6.52	5.44	13.45	45.80
18	ALFALFA	5.49	7.89	6.41	13.56	43.05
19	ALFALFA	4.53	6.69	5.44	13.66	40.53
20	ALFALFA	3.45	6.58	5.02	14.00	48.71
21	ALFALFA	5.51	8.90	8.20	14.57	36.92
22	ALFALFA	4.32	7.40	4.96	14.61	51.80
23	ALFALFA	4.37	7.10	5.80	14.73	49.17
24	ALFALFA	4.97	7.78	6.45	14.81	41.61
25	ALFALFA	6.40	8.53	10.05	14.83	37.70
26	ALFALFA	6.32	8.32	9.56	14.87	38.99
27	ALFALFA	5.91	9.28	8.18	14.98	40.41
28	ALFALFA	6.73	8.88	10.81	15.20	35.40
29	ALFALFA	6.34	8.67	10.24	15.32	35.95
30	ALFALFA	5.87	8.43	10.89	15.86	37.21
31	ALFALFA	5.72	9.13	9.58	16.26	40.43
32	ALFALFA	6.60	9.87	11.05	17.08	41.15
33	ALFALFA	7.41	10.06	11.62	17.27	35.26

ANEXO B. IMÁGENES DE CULTIVO


Imágenes de cultivo de sorgo



Imágenes cultivo de alfalfa



Imágenes cultivo de algodón



Imágenes del cultivo del maíz



Imágenes del cultivo del nogal

