



**UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS FORESTALES Y AMBIENTALES
CENTRO ESTUDIOS FORESTALES Y AMBIENTALES DE POSTGRADO**

Evaluación de metodologías para corregir el efecto de sombreado topográfico en imágenes satelitales con dos modelos digitales de elevación y dos sistemas de clasificación.

Trabajo de grado presentado por el Ingeniero David Llúncor como requisito de mérito para optar al título de Magíster Scientiae



Tutor Académico: Prof. Juan Ygnacio López Hernández Ing. MSc. PhD.

Mérida, Venezuela 2016

Contenido

Resumen	1
Introducción	3
Justificación.....	5
Objetivos	6
Marco Teórico.....	7
Metodología:	25
Selección de Imágenes	27
Reproyección.....	27
Corrección Radiométrica.	28
Recorte Espacial.....	28
Corrección Topográfica	28
Verificación y validación de Resultados de corrección topográfica.....	28
Reclasificación del NDVI	28
Clasificación Supervisada	29
Evaluación de las clasificaciones	29
Resultados	30
Conclusiones	41
Recomendaciones.....	43
Anexos	44
Bibliografía	45

Índice de Ilustraciones

Figura 1. Imagen del parque de Lam Tseun.....	11
Figura 2. Infografía Satélite Miranda.....	13
Figura 3. Cronología LANDSAT.....	14
Figura 4. Características del sensor PMC VRSS-1.....	16
Figura 5. Características del sensor WMC VRSS-1	16
Figura 6. Características del sensor OLI LANDSAT	17
Figura 7. Algoritmos de Clasificación	20
Figura 8. Hiperplanos SVM	23
Figura 9. Matriz de error	24
Figura 10. Ubicación del área de estudio.....	26
Figura 11. Imagen falso color Miranda.....	30
Figura 12. Imagen falso color OLI.....	30
Figura 13. DEM SRTM	31
Figura 14. DEM ASTERGDEM.....	31
Figura 15. Mapa de sombras VRSS-1.....	32
Figura 16. Mapa de sombras OLI	32
Figura 17. Efecto de corrección topográfica Coseno Civco	33
Figura 18. Efecto de corrección topográfica Minnaert Law	33
Figura 19. Corrección Coseno Civco SRTM	35
Figura 20. Corrección Coseno Teillet SRTM.....	35
Figura 21. Corrección Minnaert Law SRTM.....	36
Figura 22. Corrección Minnaert Law ASTERGDEM	36
Figura 23. Histograma por banda.....	37
Figura 24. Distribución de muestras de entrenamiento.....	38
Figura 25. Resultado SVM.....	39
Figura 26. Resultado NDVI	39

Abstract

The best topographic correction algorithm for Landsat (OLI) scenes and Miranda VRSS-1 (WMC) scenes was presented. The scenes used, are free on both systems. Two methods of cover classification were also compared: Reclassification of NDVI and supervised nonparametric method (SVM). Variants topographic correction was applied using elevation data (ASTERGDEM 2 and SRTM), and two topographical corrections algorithms: Cosine and Minnaert. Thematic coverage in mountainous areas in Merida layers were generated. Free software license (SAGA, R, Qgis) were used. Accuracies of classification methods were evaluated. The results were expressed through contingency tables and thematic layers resulting from the correction processes.

www.bdigital.ula.ve

Resumen

Se presentó el mejor algoritmo de corrección topográfica de escenas LANDSAT (OLI) y Miranda, VRSS-1 (WMC). Las escenas son gratuitas en ambos sistemas. Se compararon también dos métodos de clasificación de cobertura: reclasificación del NDVI y método supervisado no paramétrico (SVM). Se aplicaron variantes de corrección topográfica usando datos de elevación (ASTERGDEM 2 y SRTM), y dos algoritmos de correcciones topográficas: Coseno y Minnaert. Se generaron capas temáticas de cobertura en zonas montañosas de Mérida. Se usaron programas de licencia libre (SAGA, R, Qgis). Se evaluaron las exactitudes de los métodos de clasificación. Los resultados se expresaron a través de tablas de contingencia y las capas temáticas resultantes de los procesos de corrección.

www.bdigital.ula.ve

Introducción

El Manejo de Cuencas Hidrográficas es el proceso por el cual se coordinan actividades de conservación, manejo y uso del agua, suelos y recursos relacionados entre diferentes sectores de una cuenca hidrográfica, con el objetivo de maximizar los beneficios sociales y económicos derivados de los recursos acuíferos de una forma equitativa, al mismo tiempo que se preservan y restauran, donde sea necesario, ecosistemas de agua dulce. El conocimiento de la cobertura y uso de la tierra, es una herramienta fundamental junto a otros factores en el ordenamiento territorial dentro de la cuenca, permitiendo, ubicar fácilmente las zonas con amenazas y riesgos, además de permitir la aplicación de medidas de manejo y conservación de los recursos que se encuentren dentro de la cuenca.

El uso de imágenes provenientes de la teledetección, se ha incrementado notoriamente en los últimos años. Simultáneamente con el empleo de estas imágenes, las características de las mismas han mejorado notablemente desde el punto de vista técnico y operativo.

Las imágenes de satélites, entre otras aplicaciones ambientales permiten generar cartografía geológica, estimación de modelos de escorrentía y erosión, mapas de vegetación, mapas de uso del suelo, selección de rutas óptimas para nuevas vías de comunicación, inventarios forestales, etc.

Las imágenes de satélite constituyen una valiosa fuente para estudiar los cambios que se producen en la superficie terrestre. En un ciclo productivo basado en imágenes numéricas, es de esperar que se ahorre una importante cantidad de trabajo introduciendo procedimientos de detección de cambios que se puedan implementar en procesos de carácter automático. Desde hace unas décadas, se están utilizando como fuentes de datos para diversos usos en detección de cambios, los sensores transportados en plataformas aeroespaciales. (Sánchez García y Toral Ruiz, 2014)

Las características de este tipo de imágenes, están referidas a los tipos de resolución presentes en ellas, espacial, temporal, espectral y radiométrica, además del tipo de formato empleado en su almacenamiento y distribución.

El creciente empleo de distintos sensores de observación terrestres, está originando no solo una enorme cantidad de información, sino también una nueva forma de estudiar la superficie terrestre. La teledetección junto a las técnicas anexas de almacenamiento y proceso de la información geográfica, permiten disponer de una masa ingente de dato sobre el territorio, algunos de ellos en tiempo real. (Chuvieco 1995)

La generación automatizada de Modelos Digitales de Elevación (MDE) a partir de imágenes de satélite de alta resolución, se han convertido en una herramienta de bastante uso en los análisis de fenómenos naturales, además de servir para el pre procesamiento de imágenes de satélite, permitiendo eliminar o disminuir errores.

Las Imágenes digitales de zonas montañosas, generalmente tienen distorsiones radiométricas, conocidas como efecto topográfico. El efecto topográfico, es resultado de la diferencia de iluminación, debido al ángulo del sol y el ángulo del terreno. Esto causa una variación en los valores de brillo en la imagen. El efecto topográfico es una combinación de

- Iluminación incidente que es la orientación de la superficie con respecto a los rayos del sol
- Ángulo de exitancia es la cantidad de energía reflectada como una función del ángulo de la pendiente
- Características de cobertura de la superficie son las irregularidades del terreno, con altas montañas o pendientes empinadas.

Una manera de reducir el efecto topográfico es a través de la aplicación de transformaciones basadas en modelos de reflectancia Lambertianas y no Lambertianas. Estos modelos normalizan la imagen, lo que hace que esta se vea como si fuera una superficie plana. (ERDAS FieldGuide, 1999)

Justificación

Al trabajar con interpretación de imágenes satelitales de zonas montañosas para determinar cobertura boscosa en el manejo de cuencas, se presenta el gran problema de las zonas de umbría, zonas en las cuales, al hacer la interpretación, se pierde información, debido a que las sombras ocultan en gran parte los fenómenos que se presentan en ese lugar, para eso se necesitan hacer correcciones topográficas.

Uno de los programas satelitales internacionales que permiten obtener imágenes de alta resolución, aptas para labores inherentes a nuestra carrera de forma libre, es el programa satelital LANDSAT, siendo ya un programa maduro en el área de sensores remotos, debe aprovecharse la disponibilidad gratuita de imágenes de alta resolución que se obtienen con el nuevo sensor OLI, aun siendo este ya un programa de obtención de imágenes remotas ya establecido, siempre se hace imperativo aplicarle correcciones a las imágenes, para poder hacer labores de interpretación de manera más eficiente y disminuyendo los errores que se puedan generar por los diferentes agentes que generan interferencia al momento de capturar las imágenes.

El satélite Francisco de Miranda VRSS-1, es un sistema de captura de imágenes remotas relativamente nuevo, puesto en órbita el 28 de septiembre de 2012, además de ser un sistema satelital completamente manejado por Venezuela, la ventaja es que la obtención de imágenes de alta resolución, es gratuita. ((ABAE) <http://abae.gob.ve/contenido.php>, 2015.)

Siempre es necesario aplicar la mayor cantidad de pruebas a la información que genera, de manera tal que se pueda determinar el mejor método de pre procesamiento a aplicarle, para sacarle el mayor provecho posible al momento de hacer la interpretación, para obtener información correcta y exacta de las imágenes que se obtengan.

Objetivos

Objetivo General:

- Generar capas temáticas de cobertura en zonas montañosas de Mérida, con correcciones topográficas, usando métodos supervisados y no supervisados de clasificación.

Objetivos Específicos:

- Producir capas temáticas de cobertura.
- Determinar cuál sistema satelital (LANDSAT 8 (OLI) o Miranda (VRSS-1)) produce la mejor imagen para estudios de manejo de cuencas de la zona de Mérida.
- Determinar cuál Modelo digital del terreno se ajusta mejor a la zona montañosa de Mérida
- Determinar cuál corrección topográfica se adapta mejor a la corrección de imágenes LANDSAT 8 y VRSS-1.
- Aplicar y ajustar los parámetros del algoritmo SVM en una clasificación supervisada.
- Determinar cuál clasificador si el NDVI o el SVM dan mejores resultados al clasificar coberturas en las imágenes satelitales.

Marco Teórico

La observación terrestre es el campo encargado de monitorear y modelar procesos en la superficie terrestre y su interacción con la atmósfera. La tierra está monitoreada continuamente con radares y sensores ópticos avanzados. Las imágenes son analizadas y procesadas para producir productos útiles a usuarios individuales, agencias y organizaciones públicas. Para enfrentar esta demanda, el procesamiento de imágenes de percepción remota es actualmente un área de investigación madura, y las técnicas desarrolladas en el campo permiten tener aplicaciones, en la vida real, con gran valor social como el monitoreo urbano, detección de incendios de vegetación, de inundaciones, pueden tener un gran impacto económico y ambiental. Para lograr estos objetivos, la comunidad de percepción remota se ha convertido en un campo multidisciplinario de ciencias que abarca física, ciencia computacional, electrónica y comunicaciones. (Camps-Valls, et al, 2011)

Las distintas herramientas que se utilizan para desarrollar un manejo de cuencas integral, incluyen imágenes de satélite y demás productos, generados por sensores remotos, como los modelos digitales de elevación, permitiendo hacer correcciones topográficas de imágenes de satélite que es un proceso que se vuelve prácticamente indispensable para poder hacer una interpretación correcta de los elementos presentes en imágenes satelitales de zonas montañosas.

La exactitud y disponibilidad de imágenes de satélite, está aumentando constantemente, debido a los avances tecnológicos, como mayores resoluciones espectrales/espaciales, computadoras más potentes, el sistema de posicionamiento global (GPS) y sistemas de información geográfica (SIG). (Purkis y Klemas, 2011)

El uso de imágenes satelitales para cualquier fin, implica la corrección de una serie de efectos, distorsiones etcétera, implícitos en ellas. Cuando se trata de imágenes de zonas montañosas el efecto del relieve produce un tipo de extorsión, ya que afectan los patrones de respuesta espectral entre las caras o vertientes iluminadas y las no iluminadas (sombra).

Según Zhang y Gao (2011) ya se ha propuesto una serie de técnicas de normalización topográficas para corregir estos efectos de iluminación debido a la topografía.

Una corrección topográfica de los datos de sensores remotos ópticos, es necesaria para mejorar la calidad del análisis cuantitativo de cobertura boscosa, en terreno montañoso. La implementación de métodos de corrección semi empíricos requiere la calibración de parámetros del modelo, que fueron definidos empíricamente. (Balthazar, Vanacker, y Lambin, 2012)

En los últimos años, varios métodos de corrección topográfica han sido propuestos para corregir la diferencia de iluminación entre las áreas observadas por sensores remotos ópticos. Aunque el número de métodos de correcciones topográficas es alto, la evaluación de su desempeño depende de la existencia de información de cobertura del terreno precisa, pero un procedimiento de evaluación estandarizado y preciso, no ha sido propuesto aún. (Sola, et al. 2014).

Terrenos empinados afectan las imágenes ópticas a través de las variaciones creadas por efecto de la radiancia y de la función de distribución de reflectancia bidireccional. Para obtener la reflectancia corregida de la superficie y detectar los cambios de superficie a través del análisis de series temporales sobre superficies irregulares, es necesario remover o reducir los efectos topográficos. (Li et al., 2012).

Vanonckelen, Lhermitte, van Rompaey, y Griffiths en 2013 implementaron una corrección Minnaert basada en píxeles y se aplicó a los Cárpatos Rumanos para corregir distorsiones topográficas. Los resultados visuales muestran que los efectos de sombra se reducen en las composiciones corregidas. Más adelante, la corrección topográfica resultó en valores de reflectancia más homogéneos en el área de estudio.

Los métodos de corrección topográfica, comúnmente utilizados fueron analizados por su consistencia temporal, mediante la medida de la desviación típica (DT) en píxeles de suelo desnudo observados bajo distintos ángulos de incidencia solar.

Los métodos analizados son:

C de Teillet, coseno, Minnaert, Minnaert incluyendo la pendiente y empírico - estadístico. La disminución en DT para el método empírico -estadístico y C de Teillet en el espectro visible era mayor que 100% comparado con los otros métodos y mayor que 50% en el infrarrojo. El método empírico - estadístico generó mayormente valores de DT más bajos en los distintos análisis. Este método solo se aplica a las bandas

ópticas, y es un método solamente estadístico, pero no sobre-corrige las imágenes, siendo unos de los mayores problemas de los métodos convencionales. Este método se aplica independiente para coberturas de suelo, separando entre zonas con vegetación y zonas de suelo desnudo, utilizando un umbral de 0.4 de NDVI para la separación entre ambas. (Hantson et al., 2011, p. 51).

Métodos no Lambertianos como la corrección C o Minnaert, particularmente las modificaciones basadas en cobertura del último, deberían ser usadas. Ningún método provee correcciones efectivas bajo condiciones de baja o negativa iluminación, aunque esas condiciones son usualmente encontradas. Una aproximación integrada, incluyendo correcciones atmosféricas, pueden ofrecer la manera de reducir los efectos topográficos aun con poca iluminación. (Goslee, 2012).

Corrección Coseno.

Cuando se asumen superficies Lambertianas, esta es la corrección más ampliamente usada, propuesta por Teillet *et al.* (1982).

Usa las siguientes 3 ecuaciones

$$\cos i = \cos E \cos Z + \sin E \sin Z \cos (A0 - AS) \quad (1)$$

$$Ln(\lambda) = L(\lambda) / \cos i \quad (2)$$

$$LH = LT \cos z / \cos i \quad (3)$$

Donde

L = radiancia

Z = ángulo zenital solar

LH = radiancia para superficie horizontal

LT = radiancia observada en terreno inclinado

i = ángulo de incidencia con respecto a la normal de la superficie

E = inclinación de la pendiente

$A0$ = azimut solar

AS = aspecto de la superficie de la pendiente.

En 1980, Smith *et al.* Introdujeron una función empírica fotométrica, la constante Minnaert, para probar la suposición Lambertiana para superficies.

En el estudio de Smith *et al.* (1980), la constante Minnaert, k , se deriva linearizando la siguiente ecuación:

$$L(\lambda, e) = L_n \cos^k(\lambda) \cos^k(i) \cos^k(e) \quad (4)$$

Donde

L =radiancia

λ =longitud de onda

e =ángulo de pendiente

L_n = radiancia cuando $i=0$

k = constante Minnaert

i = ángulo de incidencia

$$L \cos e = L_n \cos^k i \cos^k e \quad (5)$$

Luego de la linearización, la ecuación (2) se transforma en:

$$\log(L \cos e) = \log L_n + k \log(\cos i \cos e) \quad (6)$$

Ahora, se puede obtener el valor de regresión de k usando la ecuación (3), de la forma línea de $y=mx+c$

Donde

$$x = \log(\cos i \cos e)$$

$$y = \log(L \cos e)$$

$$c = \log L_n$$

El valor de la constante Minnaert se encuentra entre 0 y 1. Es usada para describir la irregularidad de la superficie. Cuando la superficie tiene un comportamiento Lambertiano, el valor de la constante Minnaert es 1, en caso contrario es menor a 1. Luego que se determina la constante Minnaert, k , es determinada, de vuelta se puede desarrollar un modelo de corrección de transformación de radiancia.

$$L_n = L(\cos e) / (\cos^k i \cos^k e) \quad (7)$$

(K.H. Law , J. Nichol. 2004).

En las siguientes imágenes se puede observar la diferencia entre una imagen sin corrección y las otras con las correcciones antes mencionadas:

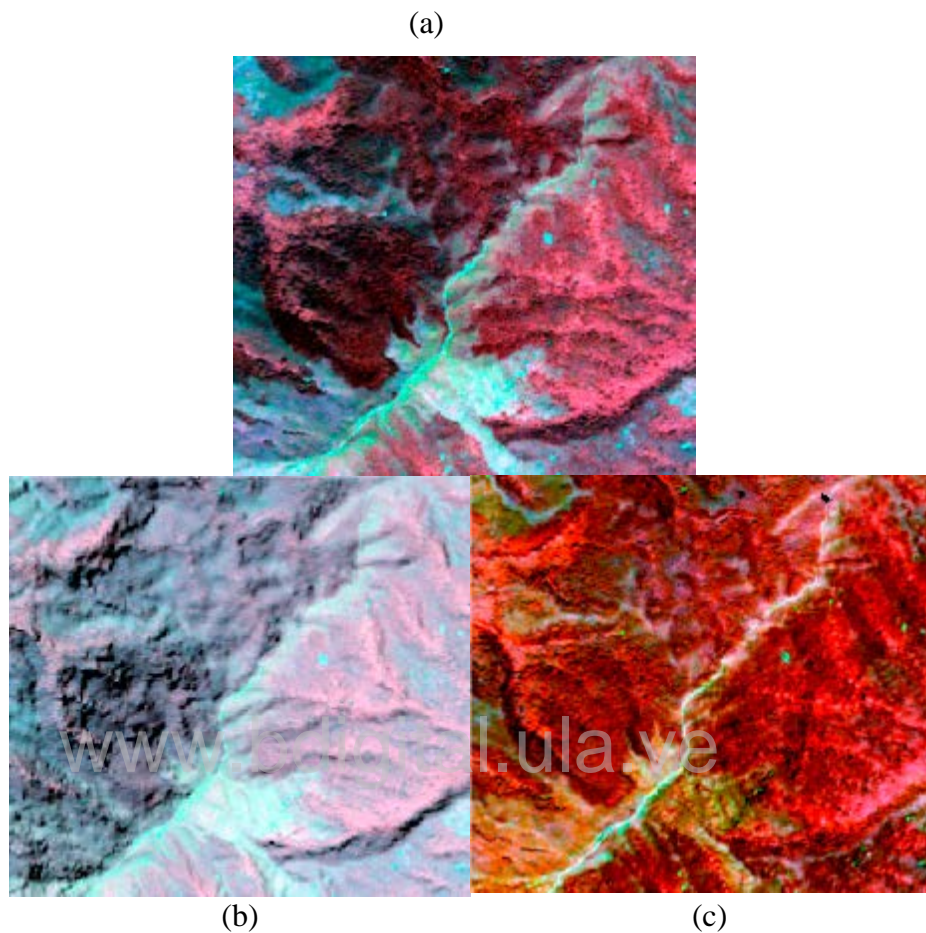


Figura 1. Imagen del parque de Lam Tseun.
imagen a falso color IKONOS, 7 Sept 2002, (a), imagen original, (b), Resultado de la Corrección Coseno, (c), Resultado de la corrección Minnaert.
(tomado de T K.H. Law, J. Nichol. 2004)

Para realizar las correcciones topográficas, se necesita tener modelos digitales del terreno como referencia, los que tenemos disponibles de manera libre son el ASTER GDEM y el SRTM.

- ASTER GDEM Versión 2: El ASTER GDEM es un producto conjunto desarrollado y puesto a disposición del público por el ministerio de economía comercio e industria (METI) de Japón y la administración nacional de aeronáutica y espacio de Estados Unidos (NASA). Es generado a partir de datos colectados a través del instrumento ASTER. El ASTER GDEM es el único

modelo de elevación digital que cubre completamente la superficie de la tierra a alta resolución. El ASTER GDEM ha sido ampliamente usado por muchos usuarios y ha contribuido grandemente a la comunidad global de observación terrestre.

El Modelo Global de Elevación Digital, del Radiómetro Avanzado de Emisiones Termal y Reflexión Espacial, fue lanzado al público en julio del 2009. El GDEM versión 2, actualmente bajo desarrollo, es producido usando un algoritmo actualizado y contiene nueva data ASTER obtenida luego de diciembre del 2008. El estudio de validación de la versión de prueba y versión beta del GDEM versión 2, llevó a investigar características como error de geolocalización, error de elevación y resolución horizontal. El resultado del estudio confirmó que los desfases elevación y resolución horizontal se mejoraron grandemente la versión 2 y la mejora de resolución horizontal servirá para reducir la desviación estándar del error de elevación y geolocalización.(Tachikawa, et al, 2011).

- SRTM: La Misión Topográfica Shuttle Radar (acrónimo en inglés SRTM, de *Shuttle Radar Topography Mission*) es un proyecto internacional entre la Agencia Nacional de Inteligencia-Geoespacial, NGA, y la Administración Nacional de la Aeronáutica y del Espacio, NASA. Su fin es obtener un modelo digital de elevación de la zona del globo terráqueo entre 56 °S a 60 °N, de modo que genere una completa base de mapas topográficos digitales de alta resolución de la Tierra. Esta base cartográfica ha sido ampliamente utilizada en diferentes campos del conocimiento relacionados con la geomática al poderse descargar gratuitamente a través de Internet. El SRTM consiste en un sistema de radar especialmente modificado que voló a bordo del transbordador espacial Endeavour durante los 11 días de la misión STS-99 de febrero de 2000. Para adquirir los datos de elevación topográfica estereoscópica la SRTM llevaba dos reflectores de antenas de radar. Cada reflector-antena estaba separado de los otros, 60 metros, gracias a un mástil que extendía la anchura del transbordador en el espacio.

La técnica empleada conjuga programas de Computación interferométrico con SAR radares con anchos “sintéticos” en sus antenas reflectoras. (Misión topográfica Radar Shuttle, 2014).

Las Imágenes de satélite de libre acceso, provienen de distintos programas satelitales, pero nos enfocaremos en los dos siguientes sistemas de sensores remotos:

- **Satélite Francisco de Miranda:** El Satélite Miranda (VRSS-1) o *Venezuelan Remote Sensing Satellite* (VRSS-1) es el primer satélite de observación remota de Venezuela. Su objetivo es tomar imágenes digitales de alta resolución del territorio venezolano. Tiene cámaras de alta resolución (PMC) y cámaras de barrido ancho (WMC). Fue lanzado desde el Centro de Lanzamiento de Satélites de Jiuquan en China el 28 de septiembre de 2012.

Miranda es el segundo satélite venezolano puesto en órbita tras el lanzamiento del Simón Bolívar el 25 de octubre de 2008. (MCTI.gob.ve. 2014)



Figura 2. Infografía Satélite Miranda.
Tomado de www.noticias24.com

Próximo Proyecto del ABAE

Se tiene previsto un próximo lanzamiento del satélite VRSS-2 Sucre; la cámara será de mayor resolución espacial que la del satélite Miranda, la cual es de 2,5 metros y en el caso del satélite Sucre será de un metro de resolución espacial. El Sucre contará con

una Cámara de Alta Resolución (HRC) y una Cámara Infrarroja, mientras que el satélite Miranda cuenta con una Pancromática Espectral y una Multiespectral de 16 metros de resolución espacial. El ancho de barrido es de 30 kilómetros mientras que el del Satélite Miranda es de 57 kilómetros lo que significa que hará el barrido a la superficie en menor tiempo. Las antenas del satélite Sucre se van a poder direccionar, van a tener movilidad, en el caso de las antenas del satélite Miranda no poseen flexibilidad. (Agencia Bolivariana para Actividades Espaciales, 2014)

- Sistema satelital LANDSAT: La constelación de satélites LANDSAT (LAND=tierra y SAT=satélite), que inicialmente se llamaron ERTS (*Earth Resources Technology Satellites*), fue la primera misión de los Estados Unidos para el monitoreo de los recursos terrestres. La forman 8 satélites de los cuales sólo se encuentran activos el 5 y el 8. Su mantenimiento y operación está a cargo de la Administración Nacional de la Aeronáutica y del Espacio (NASA) en tanto que la producción y comercialización de las imágenes depende del Servicio Geológico de los Estados Unidos (USGS). Especial mención merece el satélite LANDSAT-8, lanzado al espacio en agosto de 2012, por sus 11 bandas y amplias posibilidades de combinación lo que permitirá un mayor aprovechamiento. (landsat.gsfc.nasa.gov, 2015).

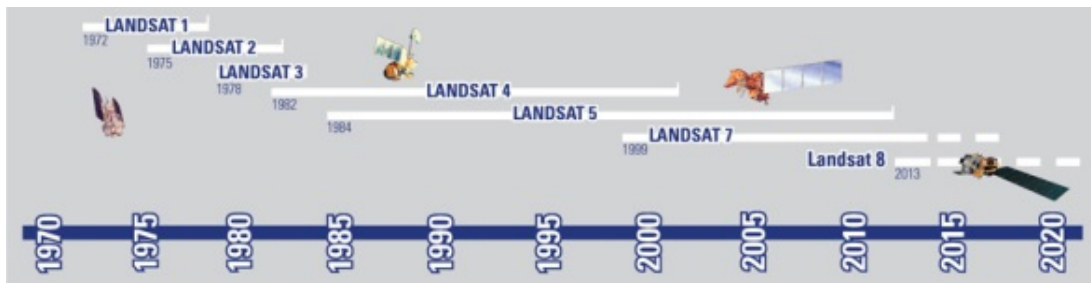


Figura 3. Cronología LANDSAT.
Fuente: <http://landsat.usgs.gov>, 2015

Comparación entre LANDSAT 8 (OLI) y Miranda (VRSS-1).

La serie LANDSAT, de la NASA, representa el programa más largo y continuo de observación terrestre en la historia, que inicia con el lanzamiento del LANDSAT-1 en 1972, hasta LANDSAT-7, con el sensor ETM+, lanzado el 15 de abril de 1999. Con la evolución del programa, se ha incrementado el énfasis de la utilidad científica de la data acompañada por los más estrictos requerimientos para instrumentos y caracterización de datos, calibración y validación. Esta tendencia, continúa con el LDCM, que es la siguiente misión en la secuencia LANDSAT. (Landsat-8/LDCM - eoPortal Directory - Satellite Missions)

LANDSAT 8. La carga efectiva consiste en 2 sensores de observación terrestre; el sensor “*Operational Land Imager (OLI)*” y el “*Thermal Infrared Sensor (TIRS)*”. Los dos sensores coincidentemente colectarán imágenes multiespectrales de la superficie terrestre, el sensor (*OLI*)”, toma imágenes en el espectro visible, infrarrojo cercano y la porción de infrarrojo de onda corta, con una resolución de 15 metros, pancromático multiespectral con una amplitud de barrido de 185 km (Garner 2013).

VRSS-1 es el primer satélite de percepción remota venezolano, nombrado en honor al Generalísimo Francisco de Miranda; la Agencia Bolivariana para Actividades Espaciales (ABAE), está a cargo de las operaciones, la gestión y la aplicación de la misión del satélite VRSS-1 en órbita. Tiene como carga útil 2 sensores el PMC (*PAN y Multispectral Camera*) y el WMC (*Wide-swath Multispectral Camera*).

PMC es un sensor de barrido de alta resolución compuesta de 2 cámaras, con capacidad de observación en el rango visible, con resolución de 2.5 metros en Pancromático y 10 metros en Multiespectral.

WMC es un sensor de barrido, con un set de 2 cámaras de media resolución, con capacidad de observación en el rango visible con una resolución espacial de 16 metros en Multiespectral. (VRSS-1 - Satellite Missions - eoPortal Directory).

Tipo de Imagen	Barrido con capacidad de Interfaz de documento con pestañas
Bandas Espectrales	Pancromática: 0.45-90 μm B1/Azul: 0.45-0.52 μm B2/Verde: 0.52-0.59 μm B3/Rojo: 0.63-0.69 μm B4/Infrarrojo Cercano 0.77-0.89 μm
Resolución	Pancromático: ≤ 2.5 m Multiespectral: ≤ 10 m
Ancho de barrido al nadir	~ 57 km
Sensor CCD	Pancromático: 10 μm x 10 μm , ≥ 12000 pixeles (una cámara) Multiespectral: 40 μm x 40 μm , ≥ 3000 pixeles totales (cada banda en una cámara)
Relación señal ruido	Pancromático: ≥ 48 dB (ángulo cenital solar = 70°, albedo de superficie = 0.65) Multiespectral: ≥ 48 dB (ángulo cenital solar = 70°, albedo de superficie = 0.65)
Masa del Instrumento	135 kg.

Figura 4. Características del sensor PMC VRSS-1.
Modificado de (VRSS-1 - Search EO Satellite Missions)

www.bdigital.ula.ve

Tipo de Imagen	Barrido con capacidad de Interfaz de documento con pestañas
Bandas Espectrales	Pancromática: 0.45-90 μm B1/Azul: 0.45-0.52 μm B2/Verde: 0.52-0.59 μm B3/Rojo: 0.63-0.69 μm B4/Infrarrojo Cercano 0.77-0.89 μm
Resolución al nadir	≤ 16 m
Ancho de barrido al nadir	~ 370 km
Sensor CCD	12000 pixeles de 6.5 μm
Sistema óptico	Sistema óptico refractivo, longitud focal = 270mm
Relación señal ruido	Multiespectral: ≥ 20 dB (ángulo cenital solar = 15°, albedo de superficie = 0.05) Multiespectral: ≥ 46 dB (ángulo cenital solar = 70°, albedo de superficie = 0.65)

Figura 5. Características del sensor WMC VRSS-1
Modificado de (VRSS-1 - Search EO Satellite Missions)

Banda N°	Nombre de Banda	Rango Espectral (nm)	Resolución	Radiancia Típica	Relación Señal Ruido
1	Azul Profundo	433-453	30 m	40	130
2	Azul	450-515	30 m (Bandas Heredadas del Sensor TM)	40	130
3	Verde	525-600		30	100
4	Rojo	630-680		22	90
5	Infrarrojo Cercano	845-885		14	90
6	Infrarrojo de onda corta 2	1560-1650		4.0	100
7	Infrarrojo de onda corta 3	2100-2300		1.7	100
8	Pancromático	500-680		23	80
9	Infrarrojo de onda corta	1360-1390		6.0	130

Figura 6. Características del sensor OLI LANDSAT
Modificado de <https://directory.eoportal.org/>, 2014

Las imágenes de satélite con fines de estudio, no se pueden utilizar directamente, sin antes aplicarle correcciones y compensaciones.

Muchas veces, al realizar los análisis a las imágenes de satélite, los resultados que podemos observar, no son los esperados en un principio, por lo que a veces hace falta realizar alguna corrección previa; una de estas correcciones y la más sencilla es la corrección radiométrica, siendo uno de los modelos más usados el modelo DOS, propuesto por Chaves (1988), que ha sido utilizado en numerosas aplicaciones probablemente por ser de aplicación simple. Postula que la bruma atmosférica incrementa los Números Digitales (ND), o brillo 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.

Los índices de vegetación y los clasificadores nos ayudan a interpretar las coberturas que observamos en las imágenes de satélite y que se presentan en el terreno.

El índice de vegetación más conocido y ampliamente usado es el *Normalized Difference Vegetation Index*, (NDVI), desarrollado por Rouse et al. En 1974. Se basa en el contraste entre la máxima absorción en la banda roja debido a los pigmentos de la clorofila, y la máxima reflexión en la banda infrarroja, causado por la estructura celular de la hoja.

NDVI es uno de los índices más usados en el seguimiento de la vegetación y por cuya simplicidad y adecuación a diferentes condiciones de contorno ha sido ampliamente referenciada. (Alonso-Benito, A. et al. 2008).

A pesar de su uso intensivo, el NDVI, se satura en casos de densas y múltiples capas de dosel y muestra una relación no lineal con los parámetros biofísicos como el verde del Índice de Área Foliar (LAI). (Haboudane et al. 2003).

El NDVI satura en los casos en que tenemos una cubierta vegetal densa y muestra una relación no lineal con parámetros biofísicos tales como el LAI (Baret y Guyot, 1991).

Además de NDVI, también se puede encontrar los siguientes índices, los cuales fueron agrupados por Haboudane, en 3 categorías, según sus características:

1° Grupo: Índices basados en la diferencia normalizada:

NDVI – Normalized Difference Vegetation Index:

Basado en el contraste entre la máxima absorción en el rojo debido a los pigmentos de clorofila y la máxima reflexión en el infrarrojo-cercano causada por la estructura celular.

RDVI – Renormalized Difference Vegetation Index.

MSR – Modified Simple Ratio.

Los dos anteriores están desarrollados para transformar en lineal la relación entre el índice de vegetación y las variables biofísicas de la vegetación.

2° Grupo: Índices de vegetación ajustados a la línea del suelo:

Creados para considerar los cambios de las propiedades ópticas del suelo. Estos índices minimizan la influencia de su reflectancia.

SAVI – *Soil-Adjusted Vegetation Index*: El factor L de la ecuación depende de la densidad de la vegetación para lo que se requiere un conocimiento previo del estado de desarrollo del cultivo.

MSAVI – *Modified SAVI*

SARVI – *Soil and Atmospherically Resistant Vegetation Index*: Para minimizar el efecto de la atmósfera en la reflectancia espectral de las cubiertas se ha incorporado la banda azul en el cálculo del índice.

3° Grupo: Índices de vegetación basados en tres bandas espectrales.

CARI – *Chlorophyll Absorption Ratio Index*: mide la

Cantidad de absorción de la clorofila en 670nm relativo al pico de reflectancia del follaje en 550nm y la reflectancia en 700nm.

MCARI – *Modified CARI*: desarrollado para reflejar la variación de la cantidad de clorofila existente en la vegetación.

TVI* – *Triangular Vegetation Index*: La idea general en el desarrollo del TVI* se basa en el hecho de que el área total del triángulo (verde, rojo, infrarrojo) aumentará como resultado de la absorción de la clorofila (disminución de la reflexión roja) y de la abundancia del tejido fino de las hojas (aumento de la reflexión en el infrarrojo cercano). (Elódio Sebem, 2005).

A continuación, se mencionan los algoritmos de clasificación que existen:

Existen varios algoritmos de clasificación; los supervisados y los no supervisados, entre los supervisados, se eligió utilizar el algoritmo *Support Vector Machines*.

1. Los supervisados:	2. Los no supervisados:
<i>Generalized linear model</i> <i>Recursive Partitioning</i> <i>Boosted Trees</i> <i>Other Boosted Models</i> <i>Random Forests</i> <i>Bagging</i> <i>Other Trees</i> <i>Multivariate Adaptive Regression</i> <i>Bagged MARS</i> <i>Elastic Net (glm)</i> <i>Neural Networks</i> <i>Partial Least Squares</i> <i>Sparse Partial Least Squares</i> <i>Support Vector Machines</i> <i>Gaussian Processes</i> <i>k Nearest Neighbors</i>	<i>Linear Least Squares</i> <i>Principal Component Regression</i> <i>Independent Component Regression</i> <i>Robust Linear Regression</i> <i>Neural Networks</i> <i>Quantile Regression Forests</i> <i>Rule Based Models</i> <i>Projection Pursuit Regression</i> <i>Penalized Linear Models</i> <i>Supervised Principal Components</i> <i>Linear Discriminant Analysis</i> <i>Quadratic Discriminant Analysis</i> <i>Stabilized Linear Discriminant</i> <i>Heteroscedastic Discriminant Analysis</i> <i>Shrinkage Linear Discriminant Analysis</i> <i>Sparse Linear Discriminant Analysis</i> <i>Stepwise Discriminant</i> <i>Stepwise Diagonal Discriminant Analysis</i> <i>Regularized Discriminant Analysis</i> <i>Mixture Discriminant Analysis</i> <i>Sparse Mixture Discriminant Analysis</i> <i>Penalized Discriminant Analysis</i> <i>High Dimensional Discriminant Analysis</i> <i>Flexible Discriminant Analysis (MARS basis)</i> <i>Bagged FDA</i> <i>Logistic/Multinomial Regression</i> <i>LogitBoost</i> <i>Logistic Model Trees</i> <i>Rule Based Models</i> <i>Bayesian Multinomial Probit Model</i> <i>Least Squares Support Vector Machines</i> <i>Nearest Shrunken Centroids</i> <i>Naive Bayes</i> <i>Generalized Partial Least Squares</i> <i>Learned Vector Quantization</i> <i>ROC Curves.</i>

Figura 7. Algoritmos de Clasificación
Tomado de: (Max Kuhn, 2010).

El algoritmo *Support Vector Machines* SVM, es un algoritmo de clasificación que poco se ha usado en Venezuela, por lo que se decide aplicarlo, para determinar su validez al clasificar coberturas en imágenes del satélite Miranda; se aplicará el análisis dirigido a pixel, ya que de esta manera se asegura mantener el control total de los parámetros de

análisis a aplicar, tomando como coberturas de estudio Bosque, Roca, Sembradío, Urbanismo, Agua.

SVM se encuentra entre los mejores (y algunos consideran que es el mejor) algoritmo supervisado de aprendizaje. Para contar la historia del SVM, primero necesitamos hablar acerca del optimizador de margen óptimo, el cual nos llevara a la digresión de la dualidad LaGrange. Veremos también kernels, que nos darán una manera de aplicar SVM eficientemente en espacios de identidad de dimensión muy alta (como infinitas dimensiones) (Andrew Ng, 2015).

El algoritmo SVM, se encuadra dentro de la clasificación supervisada, según Vapnik (1995). Pertenece a la familia de los clasificadores lineales puesto que inducen separadores lineales o hiperplanos en espacios de características de muy alta dimensionalidad (introducidos por funciones núcleo o kernel) con un sesgo inductivo muy particular (maximización del margen). (Alonso-Benito, A. et al. 2008).

Los algoritmos SVM pertenecen a la familia de los clasificadores lineales. En estos clasificadores tenemos la característica de que, a priori, conocemos las clases a las que pertenecen nuestros individuos, no se trata de una agrupación por similitudes, sino que tenemos las clases bien definidas. Dado un conjunto de ejemplos de entrenamiento (muestras) se puede etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra. Intuitivamente, una SVM es un modelo que representa a los puntos de muestra en el espacio, separando las clases por un espacio lo más amplio posible. Cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de su proximidad pueden ser clasificadas a una u otra clase, dependiendo de la proximidad a cada una. Mas formalmente, una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta (o incluso infinita) que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases permitirá una clasificación más correcta. (Sergio Aguado Rodriguez, Pedro Luis Antona Diaz, 2012).

Las SVM, son un conjunto de técnicas estadísticas que permiten clasificar una población en función de la partición en subespacios de múltiples variables. Parte de la idea de dividir de forma lineal un conjunto de múltiples dimensiones. Se crean muchos hiperplanos que dividen las observaciones. El SVM es un algoritmo que, a partir del

producto escalar de dos vectores multidimensionales, busca hiperplanos que separen los grupos. La función que define este producto escalar se denominara *kernel* y puede ser lineal, polinómica, radial o sigmoïdal. Para clasificación el SVM se plantea como un problema de programación lineal en el que se busca maximizar la distancia entre categorías sujeto a un coste y a un número óptimo de patrones de entrenamiento.

(Clasificación con SVM en R, Análisis y decisión.).

El inicio de la teoría en la que se basan las SVM data de los años setenta con los trabajos de Vapnik. En los años noventa el método fue generalizado y en la actualidad presenta un gran interés. Las SVM son nuevas estructuras de aprendizaje basadas en la teoría estadística del aprendizaje. Se basan en transformar el espacio de entrada en otro de dimensión superior (infinita) en el que el problema puede ser resuelto mediante un hiperplano óptimo (de máximo margen). La formulación de las SVM se basa en el principio de minimización estructural del riesgo que ha demostrado ser superior al principio de minimización del riesgo empírico. Las SVM presentan un buen rendimiento al generalizar en problemas de clasificación, pese a no incorporar conocimiento específico sobre el dominio. La solución no depende de la estructura del planteamiento del problema.

La idea es construir una función clasificadora que:

- Minimice el error en la separación de los objetos dados. Error en clasificación.
- Maximice el margen de separación (mejora la generalización del clasificador).

Principios básicos de la SVM:

Generalización: un clasificador o un algoritmo de regresión, aprenden a predecir correctamente los resultados de los datos ingresados, no solo de muestras ingresadas con anterioridad, sino también de muestras no tomadas en cuenta anteriormente.

Básicamente se está buscando el hiperplano de separación óptima entre dos clases, maximizando el margen entre los puntos de clases más cercanos, los puntos que se encuentran en los límites se denominan vectores de soporte y la mitad del margen es el hiperplano de separación óptima. (Meyer David, 2012)

Overfitting: un clasificador o un algoritmo de regresión, aprenden a predecir correctamente los resultados de los datos ingresados de muestras ingresadas con anterioridad, pero falla en hacerlo para muestras no tomadas anteriormente.

Overfitting, es sinónimo de una generalización pobre. (Statnikov, A. et al. 2009).

En general el Kernel RBF (*Radial Basis Function Kernel*), es una primera elección razonable. Este kernel ubica muestras en un mayor espacio dimensional de manera no lineal, a diferencia de un kernel lineal, puede manejar los casos en los que la relación entre clases y atributos no tiene comportamiento lineal. Además, el kernel lineal es un caso especial de RBF.

La segunda razón es el número de hiper parámetros, los cuales influyen la complejidad del modelo de selección.

Una clasificación cruzada puede resolver el problema de *overfitting*, para lo que se recomienda un *grid-search* en los parámetros C y γ . (Chih-Wei Hsu, et al. 2010).

Si una superficie de decisión lineal no existe, los datos son ubicados en un espacio dimensional más alto (“*feature space*”), en donde la superficie de separación puede ser hallada.

El *feature space* se construye a través de una proyección matemática (truco de kernel) (Alexander Statnikov, et al. 2009.)

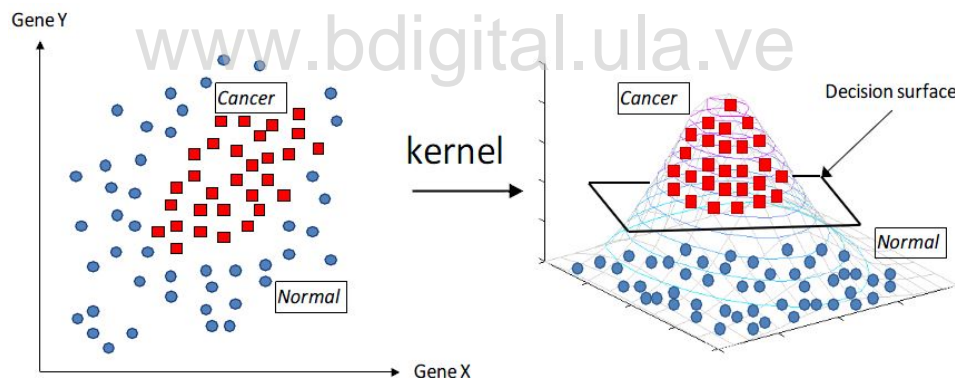


Figura 8. Hiperplanos SVM
Fuente (Alexander Statnikov, et al. 2009)

los métodos de kernel son un tipo de algoritmo que se usan para tareas de análisis de patrones, incluyendo clasificación de regresión. El ejemplo mejor conocido es el SVM, el cual ha mostrado que provee mejor desempeño generalización y otros ajustes y es significativamente mejor que otros métodos en un amplio rango de aplicaciones. (Burges 1998, citado por James Haworth y Tao Cheng, 2012)

La matriz de error es un arreglo en cuadro de números ubicados en filas y columnas, los cuales expresan los números de las unidades de muestreo (por ejemplo, pixeles,

conjuntos de píxeles o polígonos) asignados a una categoría particular, relativa a la categoría actual, verificada en terreno. Las columnas normalmente representan los datos de referencia, mientras que las filas indican la clasificación generada por la información del sensor remoto.

Una matriz de error es una forma efectiva de representar la exactitud en que la exactitud de cada categoría es claramente descrita con errores de inclusión y errores de omisión, presentes en la clasificación.

Categorías de cobertura

D: Deciduo

C: Conífera

Ba: Árido

Sb: Matorral

Exactitud total: $321/434 = 74\%$

Exactitud del proceso:

$D = 65/75 = 87\%$

$C = 81/103 = 79\%$

$Ba = 85/115 = 74\%$

$Sb = 90/141 = 64\%$

Exactitud del usuario

$D = 65/115 = 57\%$

$C = 81/100 = 81\%$

$Ba = 85/115 = 74\%$

$Sb = 90/104 = 87\%$

		Datos de Referencia				
		D	C	Ba	Sb	Total Fila
Exactitud del usuario	D	65	4	22	24	115
	C	6	81	5	8	100
	Ba	0	11	85	19	115
	Sb	4	7	3	90	104
Total Columna		75	103	115	141	434

Figura 9. Matriz de error
Modificado de (Congalton, R. G. (1991))

Metodología:

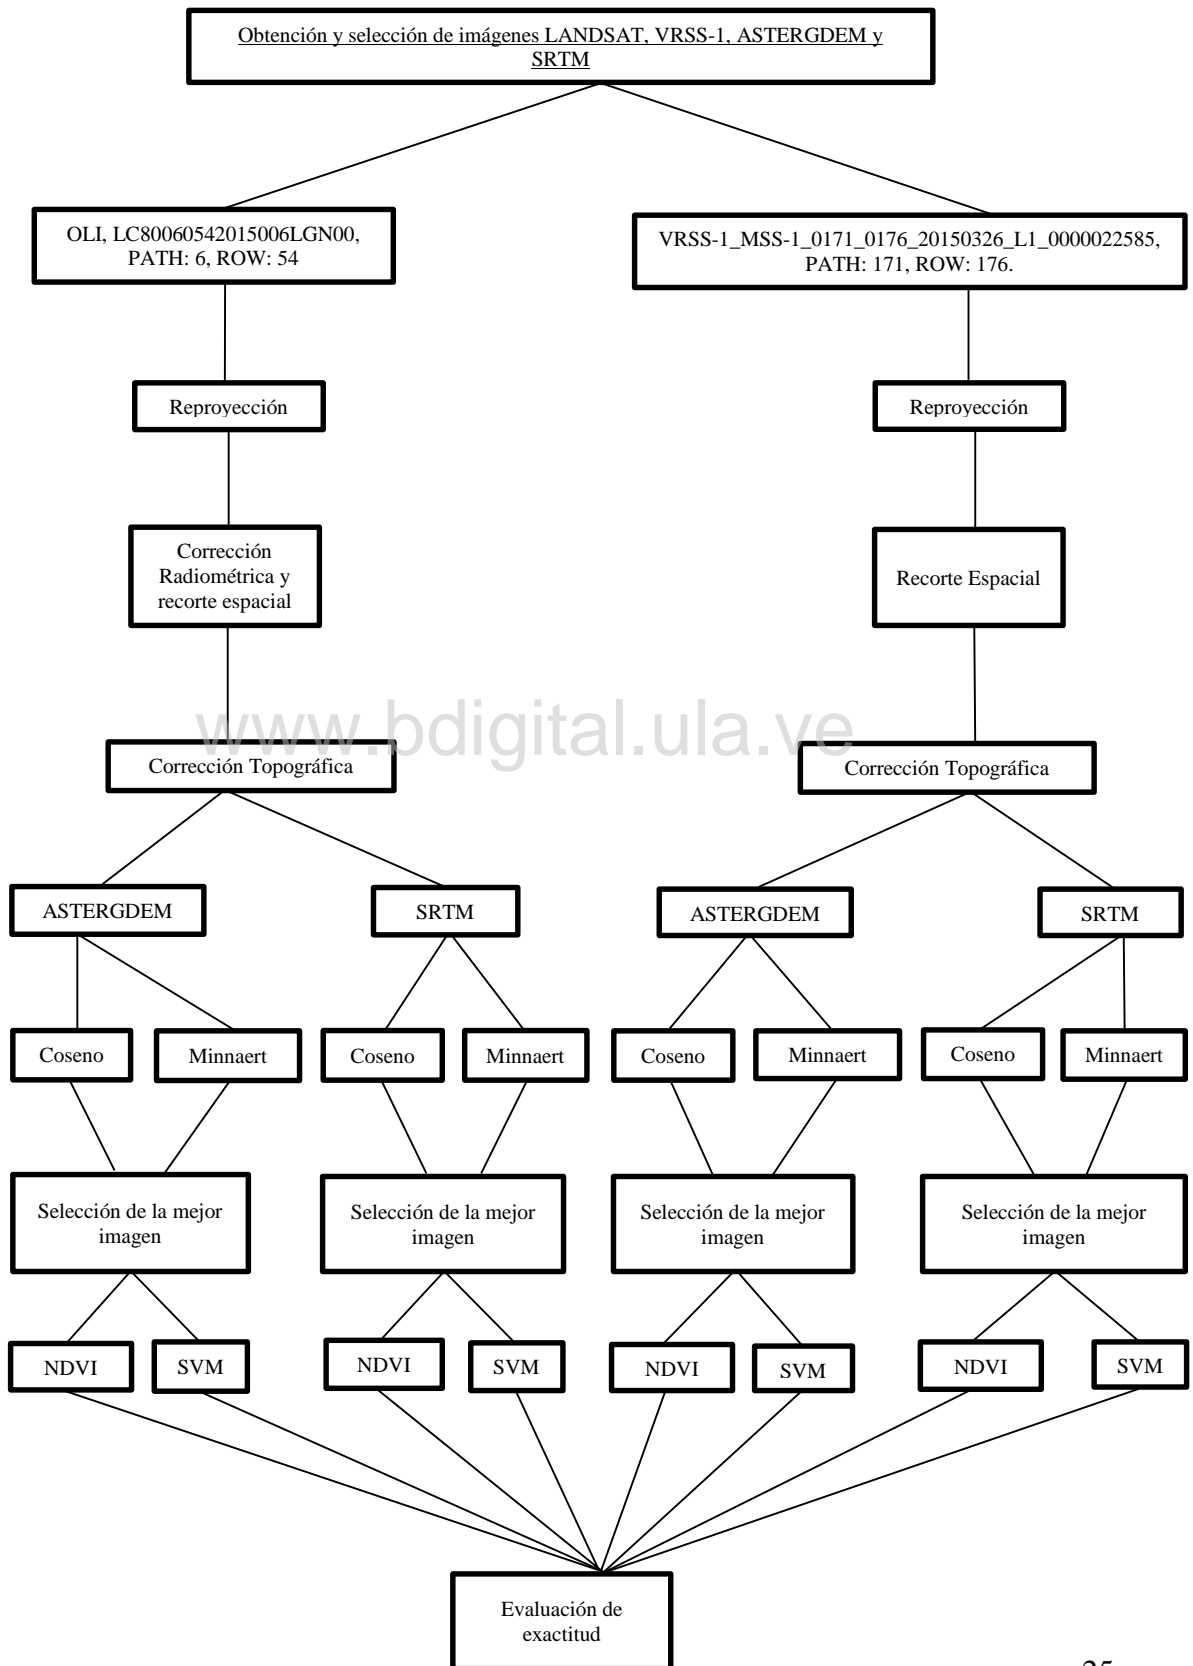




Figura 10. Ubicación del área de estudio
Fuente: Google Earth pro

En este trabajo, se evaluó el mejor algoritmo de corrección topográfica, que se puede aplicar a las imágenes del Satélite Francisco de Miranda sensor VRSS-1 y a imágenes del satélite LANDSAT 8, sensor OLI año 2015. Además, se evaluó la efectividad de aplicar dos métodos de clasificación de cobertura, uno automatizado y uno supervisado.

Selección de Imágenes

Se usaron imágenes de los sistemas satelitales LANDSAT (OLI) y VRSS-1 (WMC), el primero por ser uno de los más nuevos y el segundo, por ser el primer satélite generador de imágenes de la República Bolivariana de Venezuela y los dos, son sistemas que permiten la obtención de imágenes de satélite de manera libre.

Se descargaron imágenes del año 2015 del sensor OLI, LC80060542015006LGN00, correspondiente al PATH: 6, ROW: 54 y del sensor VRSS-1, VRSS-1_MSS-1_0171_0176_20150326_L1_0000022585 correspondiente al, PATH: 171, ROW: 176.

El área corresponde a la zona norte de la ciudad de Mérida en el estado Mérida, cubriendo parte de la cuenca del Río Mucujún, la población de la Culata, el Valle, el Playón y parte de Tabay, cubriendo también parte de la sierra de la Culata, y páramo el Escorial.

Las altitudes varían desde los 4200 msnm en el páramo de la Culata y el Escorial hasta los 1800 msnm cerca del poblado de Tabay, en los vértices tenemos las mayores altitudes del área, 4000, 4200, 2000 y 2400 msnm.

Se seleccionó esta área, ya que presenta diferentes tipos de cobertura, como selva nublada, cultivos, roca, áreas urbanas y cuerpos de agua, las cuales servirán para ejecutar los algoritmos escogidos, también tiene áreas bajo sombra y áreas iluminadas, en las cuales se aplicarían las correcciones topográficas para poder hacer el análisis respectivo.

Reproyección

En el caso de la imagen del sensor VRSS-1 realizó cambio de proyección ya que el sistema de coordenadas no correspondía al sistema proyección dado a la imagen, las imágenes OLI, y los DEM, se reproyectaron, para trabajar todas en sistema UTM zona 19N.

Corrección Radiométrica.

A las imágenes satelitales del sensor OLI, se le aplicó corrección radiométrica “Dark Object Subtraction” (DOS)

Recorte Espacial

Se hizo al recorte de la imagen de satélite utilizando el programa SAGA. correspondiente al área con una superficie de 17.447 ha, se seleccionó visualmente un área con problemas de iluminación y sombras y que además presentara diferentes tipos de cobertura. en los alrededores de la ciudad de Mérida, para ver los efectos de umbría y solana; el área seleccionada presentó varias cuencas, en las cuales se encontraron presentes distorsiones debido a la topografía.

Corrección Topográfica

Luego de recortar las imágenes se procedió a aplicar corrección topográfica teniendo como raster de elevación las imágenes de los programas SRTM y ASTERGDEM, usándolos como referencia para las correcciones topográficas, usando los algoritmos de corrección Coseno y Minnaert para cada tipo de MDE, obteniendo de estas correcciones las bandas corregidas para cada tipo de imagen; estos resultados que se compararon para determinar el que mejor se adaptó para las necesidades de interpretación para el manejo de cuencas hidrográficas.

Verificación y validación de Resultados de corrección topográfica

Luego de aplicar las correcciones, se verificó el resultado de la corrección a través de transectas en varias zonas oscuras de la imagen y se comparó el valor de brillantez, para encontrar cual algoritmo de corrección ha dado mejores resultados, obteniendo que la corrección Minnaert Law es la que mejor resultado dio tanto con VRSS-1 y OLI, así como en el ASTERGDEM y SRTM. Se determinó que la corrección Minnaert LAW se adapta mejor a las condiciones presentes en las cuencas de la zona montañosa seleccionada de Mérida, en las que, debido a la fuerte topografía, se aprecian los efectos de diferente iluminación entre unas zonas y otras.

Reclasificación del NDVI

Se realizó clasificación no supervisada NDVI para contrastar el resultado obtenido con el análisis SVM.

Clasificación Supervisada

Una vez determinado que tipo de corrección dió mejores resultados, se procedió a aplicar el análisis SVM a través del programa R, ajustando y calibrando el modelo, hasta obtener una exactitud de 100%.

De los resultados, con exactitud de 100 % se obtuvieron los valores de γ y C , los cuales se usaron para calibrar el análisis en el programa SAGA, con el cual se realizó la clasificación de las imágenes de los sensores VRSS-1 y OLI.

Evaluación de las clasificaciones

Se realizaron evaluaciones de las exactitudes de clasificación supervisada y no supervisada de imágenes de los dos sensores remotos; la clasificación no supervisada de la vegetación en las imágenes se hizo a través del índice NDVI por ser el más reportado y genera mejores resultados.

Se realizó una selección de puntos de verificación bajo patrón aleatorio o sistemático. Para analizar la relación de dependencia o independencia entre dos variables cualitativas nominales o factores, se estudió su distribución conjunta o tabla de contingencia o matriz de error.

Se procesó usando programas de licencia libre (SAGA, R, Qgis), obteniendo las capas temáticas como resultado final de la cadena de procesamiento.

Resultados

El área en el que se aplicaron los procedimientos fue la siguiente:




Figura 11. Imagen falso color Miranda

Miranda22585 001




Figura 12. Imagen falso color OLI

RT LC80060542015006LGN00




Figura 13. DEM SRTM
n08_w072_1arc_v3



Figura 14. DEM ASTERGDEM
ASTGTM2_N08W072




Figura 15. Mapa de sombras VRSS-1




Figura 16. Mapa de sombras OLI

Los gráficos de la comparación de a correcciones para el sensor OLI, con SRTM, se presentan a continuación

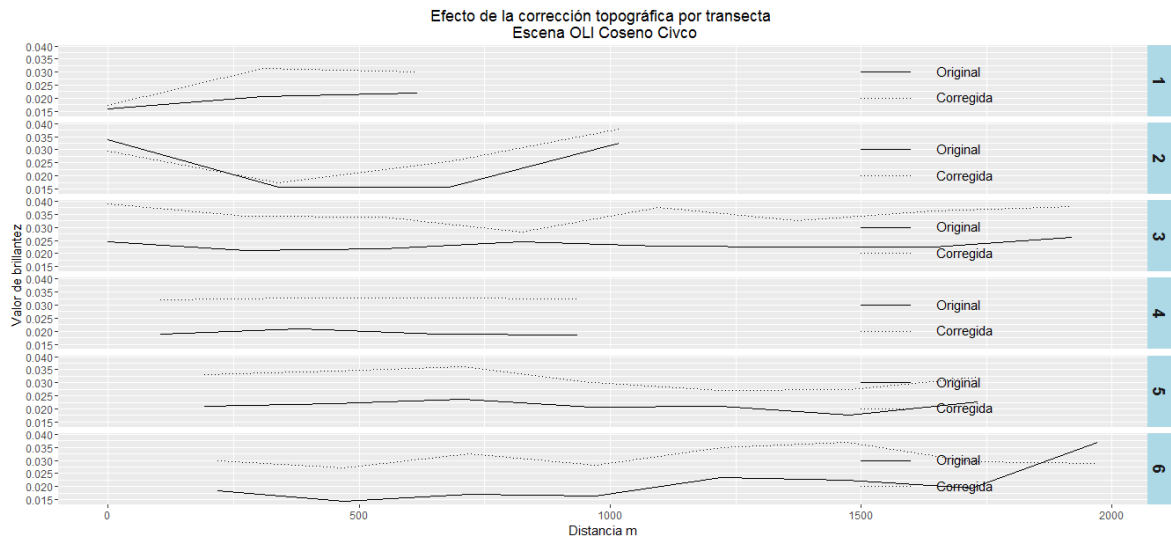


Figura 17. Efecto de corrección topográfica Coseno Civco

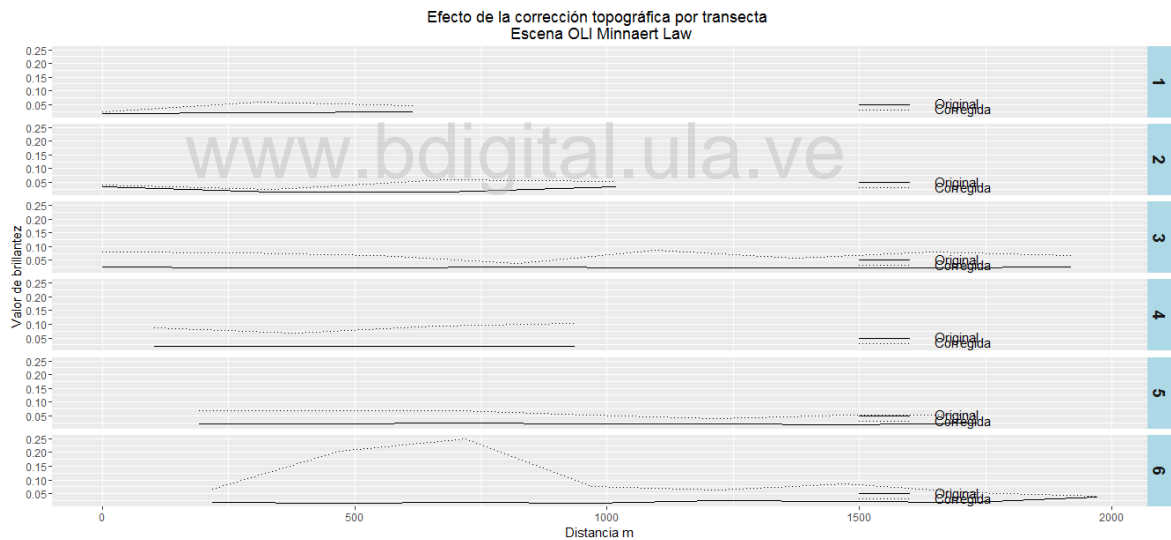


Figura 18. Efecto de corrección topográfica Minnaert Law

En la comparación de estos dos gráficos de brillantez de las imágenes corregidas, contra las imágenes originales, se puede observar claramente que las líneas correspondientes a la imagen corregida, se proyectan para estar por encima de la imagen original en la corrección Minnaert Law, mientras que en la corrección Coseno CIVCO, la corregida se mantiene por debajo de la línea de la imagen original, lo que nos indica que la corrección Minnaert Law nos ha dado mejores resultados, ha realizado mejoras en las zonas con efecto de sombras en la imagen permitiendo resaltar las características

presentes, que en la imagen original no se podían apreciar claramente; las demás gráficas de las otras correcciones, se pueden apreciar en anexos.

Además de comparar los valores de brillantez a través de los gráficos presentados anteriormente, se hizo la comparación visual de la composición a falso color de las imágenes con la corrección aplicada.

www.bdigital.ula.ve




Figura 19. Corrección Coseno Civco SRTM




Figura 20. Corrección Coseno Teillet SRTM




Figura 21. Corrección Minnaert Law SRTM




Figura 22. Corrección Minnaert Law ASTERGDEM

Luego de determinar cuál fue la mejor corrección topográfica, se establecieron áreas de muestreo a través de polígonos, en las siguientes categorías:

Roca

Bosque

Urbanismo

Cultivo

Agua

A través de la función estadísticas de cuadrícula, se determinaron los valores correspondientes a la brillantez y la frecuencia de cada una de las coberturas muestreadas, analizando la composición de cada banda a través de un histograma, que nos representa cada tipo de cobertura a analizar

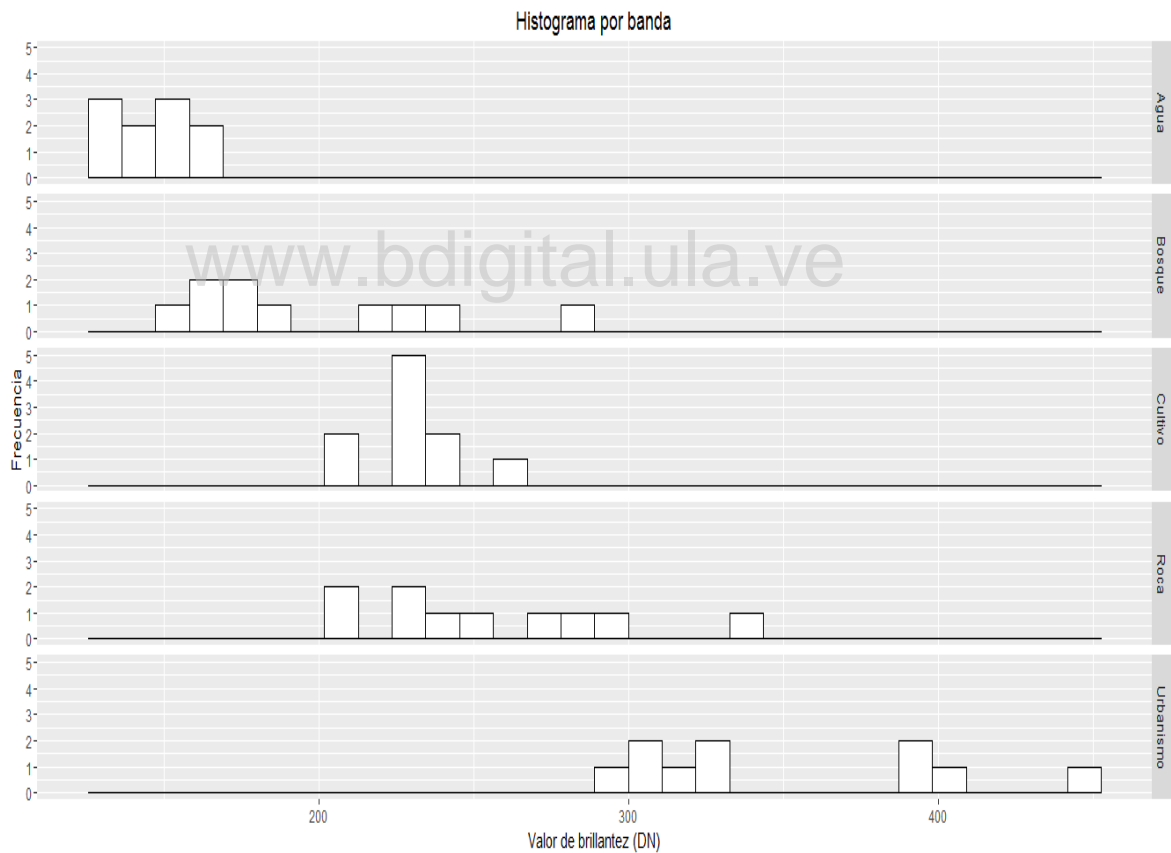


Figura 23. Histograma por banda

Luego se hizo una evaluación de la distribución de los valores de las medias de las muestras tomadas para entrenamiento con el SVM en la imagen, tomando como factores las bandas que presentan más contraste entre ellas.

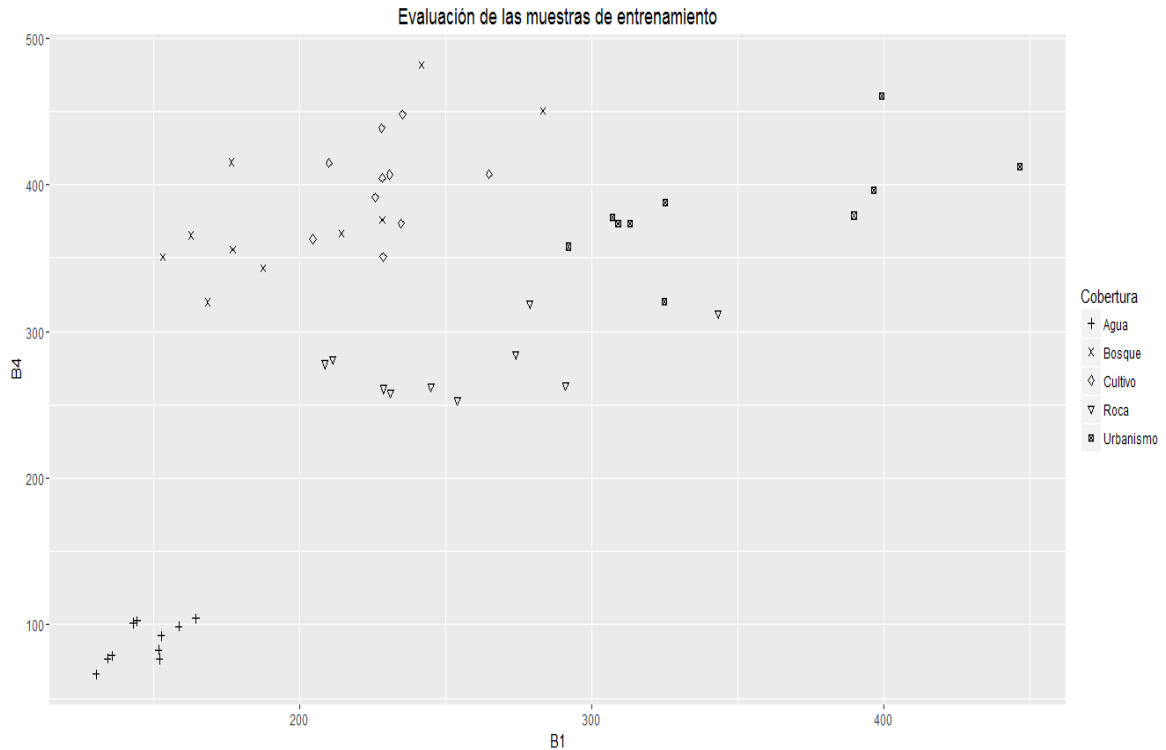


Figura 24. Distribución de muestras de entrenamiento

Con estas graficas nos aseguramos que al aplicar el algoritmo de SVM, exista poca probabilidad de que el modelo haga clasificaciones erróneas, ya que cada cobertura elegida para el análisis, se encuentra agrupada y distribuida de forma que no se intersectan una con otra.

Determinados a través del análisis, que es factible aplicar la clasificación de SVM, se procede a aplicar el entrenamiento del algoritmo, tomando las muestras antes mencionadas como muestras de entrenamiento, de los cuales se utilizó el valor de la media de cada capa correspondiente a través del paquete estadístico R, en el cual se establecieron los parámetros de GRID search, que nos permite mejorar la exactitud de la calibración del algoritmo, determinando con esta función los valores de Costo C: 6.4 y Gamma: 0.01, para realizar la clasificación. Estos parámetros se determinan a través de este procedimiento, el cual, luego se ajustó y se analizó a través de una regresión, para determinar el error presentado. Determinando que el grado de exactitud del análisis dio como resultado el 100% para cada una de las muestras aplicadas, se procedió a utilizar los valores de C y GAMMA encontrados en el programa SAGA GIS, con el comando SVM, obteniendo la siguiente clasificación




Figura 25. Resultado SVM




Figura 26. Resultado NDVI

Matriz de error

NDVI	SVM					
	1	2	3	4	5	
1	1	0	0	13	1	15
2	0	0	0	7	0	7
3	0	1	9	14	0	24
4	0	23	5	3	0	31
5	0	23	0	0	0	23
	1	47	14	37	1	100

Clases	
Agua	1
Bosque	2
Cultivo	3
Roca	4
Urbanismo	5

Exactitud Total 13%

Exactitudes		
Clase	SVM %	NDVI %
1	100	7
2	0	0
3	64	38
4	8	10
5	0	0

La matriz de error nos indica que la mayor cantidad de clases acertadas la presenta la clasificación SVM con respecto al NDVI, lo que nos indica que el SVM da mejores resultados al momento de clasificar las coberturas en el área de estudio.

Conclusiones

- Se generaron los mapas temáticos correspondientes a cada etapa del análisis de las imágenes satelitales del año 2015 del satélite LANDSAT 8 sensor OLI, LC80060542015006LGN00, correspondiente al PATH: 6, ROW: 54 y del satélite Miranda, sensor VRSS-1, VRSS-1_MSS-1_0171_0176_20150326_L1_0000022585 correspondiente al, PATH: 171, ROW: 176.
- Se hizo necesario aplicar corrección atmosférica a las imágenes del sensor OLI, ya que, al procesarlas directamente, los resultados obtenidos no eran los esperados.
- Luego de realizar las pruebas correspondientes a este estudio, se encuentra que las imágenes del sensor OLI, comparadas con el VRSS-1, son las mejores, para realizar los análisis en la zona montañosa de Mérida, ya que solamente ameritan una reproyección al sistema UTM para poder ser procesadas.
- Las imágenes VRSS-1 presentan varias deficiencias siendo la principal, la inconsistencia que presentan en el sistema de proyección, las coordenadas asignadas y el tamaño del pixel aun teniendo imágenes nivel 0, se puede conseguir este comportamiento, lo cual hace más difícil el procesamiento de las imágenes, ya que se agrega la tarea de reproyectar la imagen, para poder compensar el error, además que se necesita una segunda georreferenciación, ya que la imagen presenta áreas con grandes errores de ubicación.
- Se utilizaron dos MDE el ASTERGDEM y el SRTM, de los cuales, el SRTM de 30m de resolución, junto a la corrección Minnaert con pendiente (Law y Nichol) dió los mejores resultados al momento de realizar la corrección topográfica de las imágenes de satélite, permitiendo obtener imágenes con mejor calidad para la interpretación.
- La determinación de los valores C y Gamma para el procesamiento del SVM, aún algo empírico y se hace por tanteo, por lo que se usó el lenguaje estadístico R, para poder encontrar el valor óptimo de las variables.

- Es necesario aplicar el lenguaje estadístico R en varias oportunidades con la finalidad de hacer los cálculos estadísticos, ya que presenta más flexibilidad al momento de programar procesos de análisis.
- Utilizando el lenguaje estadístico R, se pudo calcular rápidamente los valores de C y gamma para poder ingresarlos en la herramienta SVM del software SAGA, haciendo el procesamiento más fácil y rápido.
- La determinación de los valores C y Gamma para el procesamiento del SVM, aún algo empírico y se hace por tanteo, por lo que se usó el programa R, para poder encontrar el valor óptimo de las variables.
- Al realizar la comparación visual del resultado del SVM contra el NDVI, se observa claramente que el SVM, supera ampliamente al NDVI, al momento de hacer una clasificación, obteniendo un resultado más ajustado a la realidad con la aplicación del algoritmo SVM.
- La matriz de error nos da como resultado que la mayor cantidad de aciertos por clase las da la clasificación del algoritmo SVM.

www.bdigital.ula.ve

Recomendaciones

- Dar más énfasis en el aprendizaje de paquetes estadísticos, ya que permite tener al alcance de las necesidades, muchas herramientas, que facilitan el trabajo de análisis y toma de decisiones en el proceso de investigación.
- Realizar un análisis de la fiabilidad de los MDE, con la finalidad de detectar errores en los datos, para evitar generar información con errores.

www.bdigital.ula.ve

Anexos en CD:

1. Mapa de sombreados de los MDE.
2. Correcciones topográficas de cada imagen.
3. Transectas de evaluación de áreas sombreadas vs corregidas.
4. Clases para el entrenamiento del SVM.
5. NDVI y SVM generados de las correcciones seleccionadas.
6. Puntos aleatorios para la evaluación de exactitud.
7. Tablas de contingencia para evaluar la exactitud de los NDVI y los SVM generados.

www.bdigital.ula.ve

Bibliografía

- (ABAE)Agencia Bolivariana para Actividades Espaciales. (s. f.). Recuperado 15 de octubre de 2014, a partir de <http://abae.gob.ve/contenido.php?id=VRSS-1>
- Aguado Rodriguez Sergio, Pedro Luis Antona Diaz, 2012. (s. f.). Recuperado a partir de <http://eprints.ucm.es/16102/1/Memoria.pdf>
- Alexander Statnikov, et al. 2009. (s. f.).
- Alonso-Benito, A. et al. 2008. (s. f.). Recuperado a partir de http://age-tig.es/gran_canaria08/ponencia_3/Alonso%20Benito%20et%20al.pdf
- Balthazar, V., Vanacker, V., y Lambin, E. F. (2012). Evaluation and parameterization of ATCOR3 topographic correction method for forest cover mapping in mountain areas. *International Journal of Applied Earth Observation and Geoinformation*, 18, 436–450.
- Camps-Valls, G., Tuia, D., Gómez-Chova, L., Jiménez, S., y Malo, J. (2011). *Remote Sensing Image Processing*. Morgan y Claypool Publishers.
- Chih-Wei Hsu, et al. 2010. (s. f.). Recuperado a partir de <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>
- Chuvieco 1995.pdf. (s. f.).
- Congalton, R. G. (1991). (s. f.). Recuperado a partir de <http://uwf.edu/zhu/evr6930/2.pdf>
- Elódio Sebem, 2005. (s. f.). Recuperado a partir de http://oa.upm.es/78/1/TesisDoctoral_ElodioSebem_Acrobat_6.pdf
- ERDAS FieldGuide.pdf. (s. f.).
- Exitoso lanzamiento del Satélite Miranda desde China | MCTI.gob.ve. (s. f.). Recuperado a partir de <http://www.mcti.gob.ve/actualidad/noticias/exitoso-lanzamiento-del-satelite-miranda-desde-china>
- Garner, R. (2013, junio 24). Landsat 8 Instruments [Text]. Recuperado 7 de octubre de 2014, a partir de <http://www.nasa.gov/content/landsat-8-instruments>
- Goslee, S. C. (2012). Topographic Corrections of Satellite Data for Regional Monitoring. *Photogrammetric Engineering y Remote Sensing*, 78(9), 973-981. <http://doi.org/10.14358/PERS.78.9.973>

- Haboudane et al. 2003. (s. f.). Recuperado a partir de http://quantalab.ias.csic.es/pdf/paper_rse_haboudane_lai.pdf
- Hantson, S., Chuvieco, E., Pons, X., Domingo, C., Cea, C., Moré, G., ... Tejeiro, J. A. (2011). Cadena de pre-procesamiento estándar para las imágenes Landsat del Plan Nacional de Teledetección. *Revista de Teledetección*, 36, 51–61.
- Haworth James, Tao Cheng. Non-parametric regression for space–time forecasting under missing data.pdf.
- History« Landsat Science. (s. f.). Recuperado a partir de http://landsat.gsfc.nasa.gov/?page_id=2281
- Landsat-8/LDCM - eoPortal Directory - Satellite Missions. (s. f.-a). Recuperado 21 de octubre de 2014, a partir de <https://directory.eoportal.org/web/eoportal/satellite-missions/l/landsat-8-ldcm>
- Landsat-8/LDCM - eoPortal Directory - Satellite Missions. (s. f.-b). Recuperado a partir de <https://directory.eoportal.org/web/eoportal/satellite-missions/l/landsat-8-ldcm>
- Landsat Missions Timeline. (s. f.). Recuperado 15 de octubre de 2014, a partir de http://landsat.usgs.gov/about_mission_history.php
- Li, F., Jupp, D. L. B., Thankappan, M., Lymburner, L., Mueller, N., Lewis, A., y Held, A. (2012). A physics-based atmospheric and BRDF correction for Landsat data over mountainous terrain. *Remote Sensing of Environment*, 124, 756-770. <http://doi.org/10.1016/j.rse.2012.06.018>
- Max Kuhn, 2010. The Caret Package. Recuperado a partir de <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.180.1563&rep=rep1&type=pdf>
- Meyer David. (2012). Support Vector Machines. The Interface to libsvm in package e1071. Technische Universität Wien, Austria.
- Monográfico. Clasificación con SVM en R. Análisis y decisión. (s. f.). Recuperado a partir de <http://analisisydecision.es/monografico-clasificacion-con-svm-en-r/>
- Ng Andrew, Support Vector Machines [https://datajobs.com/data-science-repo/Support-Vector-Machines-\[Andrew-Ng\].pdf](https://datajobs.com/data-science-repo/Support-Vector-Machines-[Andrew-Ng].pdf)

- Purkis, S. J., y Klemas, V. V. (2011). *Remote Sensing and Global Environmental Change*. John Wiley y Sons.
- Sánchez García, A., y Toral Ruiz, N. (2014). Análisis de las capacidades de los sistemas Landsat y E01 para la actualización cartográfica. Estudio de un caso práctico. Recuperado a partir de <http://oa.upm.es/26849/>
- Sola, I., Gonzalez-Audicana, M., Alvarez-Mozos, J., y Torres, J. L. (2014). Synthetic Images for Evaluating Topographic Correction Algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3), 1799-1810. <http://doi.org/10.1109/TGRS.2013.2255296>
- Statnikov, A. et al. 2009. (s. f.). Recuperado a partir de <http://webdoc.nyumc.org/nyumc/files/chibi/user-content/Final.pdf>
- Tachikawa, T., Hato, M., Kaku, M., y Iwasaki, A. (2011). Characteristics of ASTER GDEM version 2. En *Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International* (pp. 3657–3660). IEEE. Recuperado a partir de http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6050017
- TOPOGRAPHIC CORRECTION FOR DIFFERENTIAL ILLUMINATION EFFECTS ON IKONOS SATELLITE IMAGERY. (s. f.). Recuperado a partir de <http://www.cartesia.org/geodoc/isprs2004/comm3/papers/347.pdf>
- Vanonckelen, S., Lhermitte, S., van Rompaey, A., y Griffiths, P. (2013). Integration of topographic correction in a pixel-based compositing algorithm in the Romanian Carpathians. En *MultiTemp 2013: 7th International Workshop on the Analysis of Multi-temporal Remote Sensing Images* (pp. 1-4). <http://doi.org/10.1109/Multi-Temp.2013.6866012>
- VRSS-1 - Satellite Missions - eoPortal Directory. (s. f.). Recuperado 17 de octubre de 2014, a partir de <https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/vrss-1>
- VRSS-1 - Search EO Satellite Missions. (s. f.). Recuperado a partir de https://directory.eoportal.org/web/eoportal/satellite-missions/pag-filter/-/asset_publisher/8jbNpfmcMhvK/content/vrss-1?redirect=https%3A%2F%2Fdirectory.eoportal.org%2Fweb%2Feoportal%2Fsatellite-missions%2Fpag-

filter%3Fp_p_id%3D101_INSTANCE_8jbNpfmcMhvK%26p_p_lifecycle%3D0%26p_p_state%3Dnormal%26p_p_mode%3Dview%26p_p_col_id%3Dcolumn-1%26p_p_col_pos%3D1%26p_p_col_count%3D2%26_101_INSTANCE_8jbNpfmcMhvK_advancedSearch%3Dfalse%26_101_INSTANCE_8jbNpfmcMhvK_keywords%3D%26_101_INSTANCE_8jbNpfmcMhvK_selectedTag%3Dland%26_101_INSTANCE_8jbNpfmcMhvK_selectedTag%3Dearth-observation%26_101_INSTANCE_8jbNpfmcMhvK_delta%3D15%26_101_INSTANCE_8jbNpfmcMhvK_cur%3D7%26_101_INSTANCE_8jbNpfmcMhvK_andOperator%3Dtrue

Zhang, W., y Gao, Y. (2011). Topographic correction algorithm for remotely sensed data accounting for indirect irradiance. *International Journal of Remote Sensing*, 32(7), 1807-1824. <http://doi.org/10.1080/01431161003623441>

www.bdigital.ula.ve