

Artículo de investigación

Generación de Información Temática de la Reserva Natural de Mar Chiquita a través de Geomática

Alfredo R. Cuello¹⁻², Ailín S. Ortone Lois¹⁻²⁻³, Miriam E. Antes¹⁻² y Guido Pilato³

¹ PRODITEL, Universidad Nacional de Luján

² CSR, Fuerza Aérea Argentina

³ Universidad Tecnológica Nacional

E-mail: alfredo.cuello@gmail.com - selperargentina@mail.com - aortone@frh.utn.edu.ar
guidopilato@hotmail.com

Recibido: 30/04/2023; Aceptado: 15/06/2023; Publicado: 27/07/2023

Resumen

Este trabajo se enmarca en un proyecto que plantea el desarrollo, análisis y validación de metodologías basadas en técnicas de Teledetección cuya línea de investigación está relacionada con el estudio de Reservas Naturales de la Defensa. El área seleccionada corresponde a la Reserva Natural de la Defensa "Campo Mar Chiquita - Dragones de Malvinas". La misma abarca una superficie de 1700 has, propiedad de la Fuerza Aérea Argentina y corresponde a la ecorregión del Pastizal Pampeano. El objetivo del trabajo fue generar información temática de la Reserva y áreas aledañas referente al estado actual de conservación de los ambientes y recursos naturales presentes, para su gestión y manejo. Se utilizaron imágenes correspondientes al satélite Sentinel 2A/MSI (Multi Spectral Instrument) y al Sentinel 1B/ SAR (Synthetic Aperture Radar). Se aplicaron técnicas de clasificación supervisada a través del algoritmo de Random Forest a la imagen óptica y a la compuesta por datos ópticos, radar y bandas texturales. Esta última dio como resultado una mejor precisión en la clasificación que empleando únicamente a las bandas de la imagen óptica, especialmente en las clases de Pastizal salobre y forestal. Resulta importante poder adquirir imágenes satelitales gratuitas, ópticas y de radar, correspondientes al Programa Copérnico.

Palabras clave: Reserva natural, Defensa, Teledetección, Radar, Multisensores

Geomatic Analysis and Generation of Thematic Maps in Mar Chiquita Natural Reserve

Abstract

This paper is part of a project whose purpose is to develop, analyze and validate methodologies based on Remote Sensing techniques. Its line of research focuses on the evaluation of land covers in Nature Reserves of Defense. The area selected is the Nature Reserve of Defense "Campo Mar Chiquita - Dragones de Malvinas". The Defense Natural Reserve covers an area of 1,700 hectares, under the jurisdiction of the Argentine Air Force, and belongs to the Pampeano Pasture ecoregion. The objective of the paper was to generate thematic information on the Reserve and surrounding areas, considering the current state of conservation of the environments and natural resources, for their management. Sentinel 2A/MSI (Multi-Spectral Instrument) and Sentinel 1A/ SAR (Synthetic Aperture Radar) images were used. A supervised Classification technique through a Random Forest algorithm was performed over the optical image and an image composed of optical, radar, and textures bands. This last image showed better accuracy results, considering the optic, especially in the classes of brackish

grassland and forestry. It is important to have freely available optical and radar satellite images from the Copernicus Program.

Keywords: Natural reserve, Defense, Remote Sensing, Radar, Multisensor

1. Introducción

En el año 2007 el Ministerio de Defensa (MINDEF) y la Administración de Parques Nacionales (APN) de Argentina, firmaron un Convenio Marco de Cooperación con el objetivo de desarrollar de forma conjunta políticas activas en materia de conservación de la biodiversidad y el patrimonio arqueológico del país. Este acuerdo permitió declarar áreas que poseen interés conservacionista, como Espacio de Interés para la Conservación de la Biodiversidad (ENIC) y transformarlas en Reserva Natural de la Defensa.

Se establecieron, hasta el momento, nueve Reservas Naturales de la Defensa: Punta Buenos Aires, Puerto Península, Campo Mar Chiquita – Dragones de Malvinas, La Calera, Campo Garabato, Isla El Tala, Baterías- Charles Darwin, Ascochinga y Quebrada del Portugués. Las mismas poseen un gran valor desde el punto de vista de la conservación por resguardar ambientes y especies que no estaban incluidas en el Sistema Nacional de Áreas Protegidas. En cada una de estas reservas se planifican e implementan acciones de conservación y protección del ambiente, así como programas de formación, investigación y divulgación del patrimonio natural y cultural de la Nación, manteniendo y asegurando el normal desenvolvimiento de la utilización militar primaria. Los mecanismos de restauración de ambientes naturales originales, la minimización del impacto ambiental propio de las actividades militares o la adopción de estándares para la medición de estas, son algunas de las acciones que se impulsan en estas áreas protegidas.

Para este trabajo se consideró la Reserva Natural de la Defensa Campo Mar Chiquita - Dragones de Malvinas, dependiente de Fuerza Aérea Argentina y declarada como tal el 16 de junio de 2009. Esta Reserva Natural se extiende sobre 1.753 hectáreas linderas a la boca de la albufera Mar Chiquita, sobre la costa atlántica de Buenos Aires, que, desde 1996, forma parte de la Reserva de la Biosfera Parque Atlántico Mar Chiquito, del programa Intergubernamental e Internacional MAB de la UNESCO.

Las albuferas, lagunas litorales comunicadas con el mar (Neiff et al., 2004), son importantes desde el punto de vista ecológico pues poseen abundancia de vegetación acuática y de fauna ictícola que acude a desovar, como asimismo son escala migratoria de aves que la utilizan como fuente de alimentación en sus viajes.

Esta área protegida presenta algunos problemas para su conservación que están relacionados con el efecto del cambio climático y por la presión ejercida por el uso de la tierra sobre la región donde está inmersa (frontera agrícola ganadera y aumento del turismo) (Maceira et al., 2005). Por estos motivos, una vez creada la Reserva se comenzó con el diseño de un plan de evaluación de la biodiversidad presente en el área, a los fines de obtener información de sus componentes y de la condición ambiental de la misma.

Los ecosistemas costeros tienen una gran biodiversidad y son muy vulnerables a los cambios producidos por las actividades humanas, la introducción de especies exóticas y otros factores. Por lo tanto, dada la importancia de estos ecosistemas litorales, es importante disponer de información sistemática y eficiente para la monitorización de estas áreas protegidas (Wang, 2010).

El avance tecnológico de los últimos tiempos hace posible una gran disponibilidad de información satelitaria, de distintos tipos de sensores, procesos y algoritmos y la obtención de una variedad de

productos, los cuales son utilizados cada vez más para elaborar cartografía y para el monitoreo y análisis de la cobertura terrestre y la vegetación.

Asimismo, combinar datos ópticos y de microondas puede ayudar al mapeo de características biofísicas de humedales y vegetación e incrementar la precisión de clasificaciones en humedales (Kaplan & Avdan, 2018). El uso combinado de estos datos se aplicó en diversos estudios para caracterizar ecosistemas, tales como: humedales (Rodrigues & Souza-Filho 2011), áreas con uso agrícola (Hill et al., 2005, Peters et al., 2011), bosques (Montesano et al., 2013; Reiche et al., 2015) y tipos de cubiertas de suelo (Ullmann et al., 2014). Sin embargo, hasta ahora, hay pocos estudios que utilicen la potencialidad de datos ópticos y de radar combinados para mapear y caracterizar áreas de conservación, como es el caso de este estudio.

Según Antes 2020, con la llegada de las series Sentinel-1 y Sentinel-2, los métodos de análisis, procesamiento y la libre disponibilidad de sus datos, hacen que su utilización aumente cada vez más en el campo de la cartografía. Estos satélites Sentinel se han convertido en referencia mundial en la observación de la tierra.

El presente trabajo se basa en la utilización de imágenes multisensores correspondientes al satélite Sentinel 2A y al Sentinel 1B/ SAR considerando para la clasificación, un método de aprendizaje automático Random Forest, como así también la incorporación de información relativa a la textura de los datos SAR. Según Zhou y Robson (2001) la incorporación de variables texturales es necesaria para obtener una adecuada clasificación.

En este contexto, se plantea como objetivo general del trabajo elaborar cartografía temática para analizar el estado actual de la Reserva Natural de la Defensa Campo Mar Chiquita - Dragones de Malvinas, mediante el uso de imágenes ópticas y de radar, generando información dinámica y confiable respecto a la conservación de los recursos naturales y ambientes asociados.

2. Materiales y métodos

Área de Estudio

El área de estudio abarca la Reserva Natural de la Defensa Campo Mar Chiquita - Dragones de Malvinas y áreas aledañas correspondientes a la Reserva Mundial de Biosfera Parque Atlántico Mar Chiquito (Figura 1).

Figura 1. Localización del área de estudio (Imagen Sentinel 2A)



Fuente: elaboración propia.

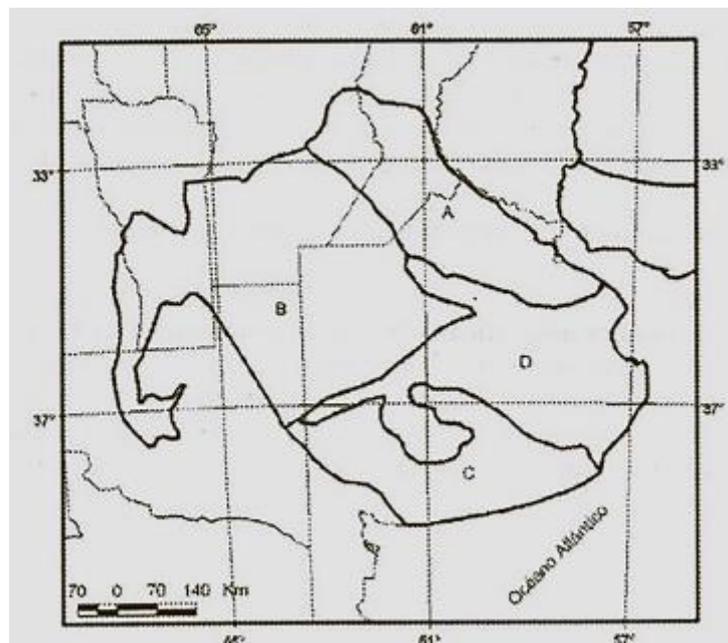
La albufera de Mar Chiquita se extiende en sentido NE-SW paralela a la costa y separada del mar por cordones arenosos, pero conectada a éste por una boca. El hecho de ser un ecosistema costero con una laguna de agua dulce conectada al mar convierte al área en un lugar de características únicas y especiales que no es común observar (Cuello et al., 2011).

Al recibir agua de origen marino y continental cualquier variación en los volúmenes aportados por ambos ambientes se traduce en variaciones de salinidad dentro del espejo, la cual aumenta, en general en el verano a causa de las intensas evaporaciones.

Esta área corresponde a la ecorregión del pastizal pampeano, importante desde el punto de vista de la conservación, dado que en ella se preservan los ecosistemas más representativos de los pastizales autóctonos de la zona, presentando flora y fauna de diferentes subambientes: planicies mareales, llanura de inundación, marismas, deltas mareales, barrera de médanos, depresiones intermedanasas y paleoplayas compuestas. En el área, se encuentran comunidades de: pastizales de pastos altos y cortos, vegetación psámofila, bañados y médanos. En cuanto a los pastizales de pastos altos, los tipos presentes son los espartillares, juncales y cortaderas.

El área de estudio se encuentra localizada en la región denominada "Pastizales del Río de la Plata" (Soriano et al., 1992), entre la Pampa Deprimida y la Austral (Figura 2).

Figura 2. Subdivisiones regionales de los pastizales de la provincia de Buenos Aires A. Pampa ondulada, B. Pampa interior, C. Pampa austral, D. Pampa deprimida



(Fuente: Soriano et al, 1992)

En relación con los biomas antrópicos generados por la modificación en el uso de la tierra, siguiendo la clasificación de Ellis (2010), si bien el área de la Reserva es considerada como de pastizales sin poblaciones humanas significativas, toda la región del entorno de esta se encuentra dominada por biomas antropizados de cultivo y son estos los que más han crecido en superficie en el último siglo. El clima es templado - húmedo, con influencia oceánica, tiene precipitaciones durante todo el año, los veranos son frescos y los suelos arenosos y arcillosos.

El área de estudio tiene un valor ecológico importante por su diversidad florística y faunística, representa una zona de transición entre la biodiversidad marina y la terrestre, aspectos que enriquecen la biodiversidad biológica, pero al mismo tiempo dan fragilidad al ecosistema.

Materiales

Se emplearon imágenes ópticas correspondientes al Satélite Sentinel 2 A/MSI (Multi Spectral Instrument) e imágenes radar correspondientes al Sentinel 1B/ SAR (Synthetic Aperture Radar) (Tabla 1, 2).

Tabla 1. Características, Satélite Sentinel 2 A MSI

Satélite / Sensor	Bandas	Resolución Espacial (m)	Resolución Espectral (µm)
Sentinel 2A/ MSI (Multi Spectral Instrument)	1	60	0,43-0,45
	2	10	0,45-0,52
	3	10	0,54-0,57
	4	10	0,65-0,68
	5	20	0,69-0,71
	6	20	0,73-0,74
	7	20	0,77-0,79
	8	10	0,78-0,90
	8A	20	0,85-0,87
	9	60	0,93-0,95
	10	60	1,36-1,39
	11	20	1,56-1,65
12	20	2,10-2,28	

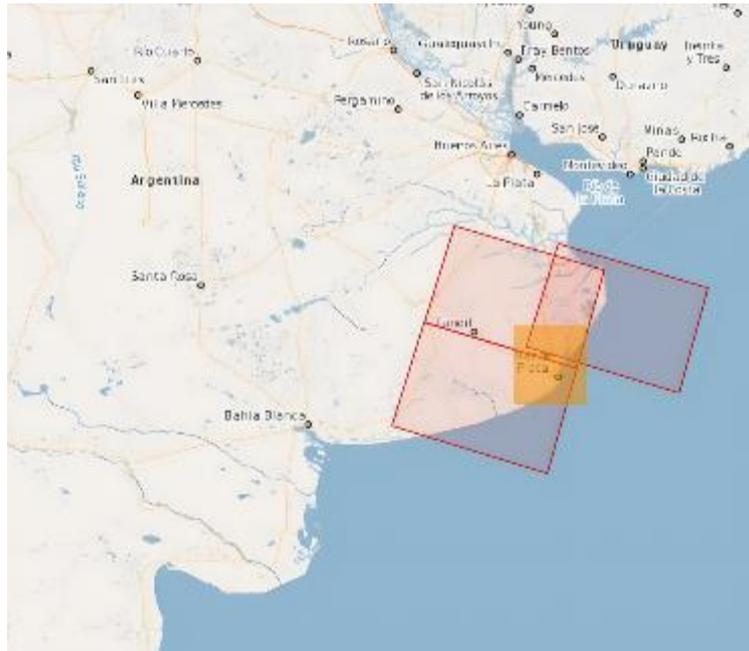
Tabla2. Características Satélite Sentinel1B/ SAR

Sat élite / Sensor	Banda	Modo de Imagen SAR	Polarización
Sentinel 1B Synthetic Aperture Radar	C	Stripmap (GSD 5m, 80 km swath)	VV+VH o HH+HV
		Interferometric	
		Wide swath- Mode (GSD: 5*20m, 240km swath)	
		Extra Wide Swath Mode (400km Swath, single-look)	
		Wave Mode (20*5m)	

La imagen óptica, Sentinel-2A_MSIL1C, del 20 de enero de 2021, fue elegida considerando la fecha, la baja nubosidad y la buena calidad.

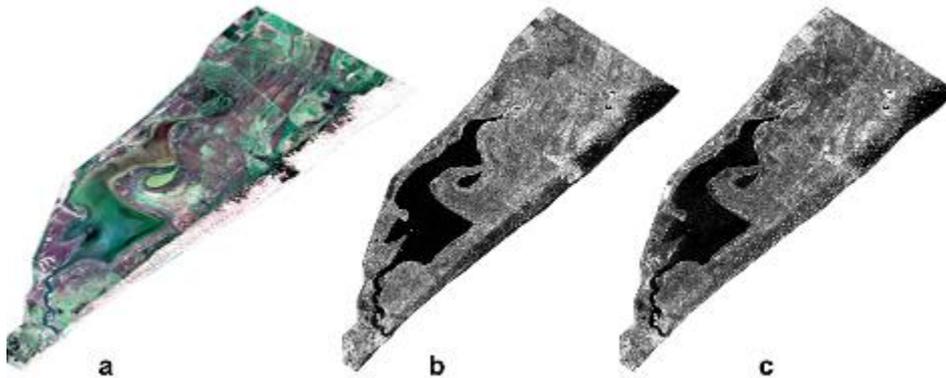
Las tres imágenes radar, Sentinel 1B – SAR, poseen características semejantes: órbita descendente, doble polarización VH y VV, producto GRD (Ground Detected), con el mismo modo de adquisición IW (Interferometric Wide) y corresponden a dos fechas distintas (14 y 19 de enero de 2021) debido a que no cubre la totalidad del área en una sola pasada del satélite (Figura 3).

Figura 3. Cobertura de las imágenes según la pasada del satélite



Para delimitar la reserva se contó con el vectorial correspondiente a la Reserva de Biósfera Parque Atlántico Mar Chiquito del Sistema de Información de Biodiversidad de la Administración de Parques Nacionales. (referencia: <https://sib.gob.ar/index.html#!/areas-protegidas>). En la Figura 4 se observa la imagen Sentinel óptica (a), y los mosaicos correspondientes a las imágenes Sentinel radar, polarización VH (b) y HH (c).

Figura 4. (a) Imagen Sentinel 2A (b) Imagen SAR en polarización VH (b) y HH (c)



Metodología

Las bandas espectrales correspondientes a la imagen Sentinel 2A MSI se remuestrearon a un píxel de 10 metros. Para la correcta interpretación de los datos y su integración con imágenes de otros sensores se aplicaron a las imágenes SAR los procesos de calibración y corrección geométrica, estas deben ser corregidas geoméricamente y remuestreadas utilizando la información de datos de órbita y de elevación de terreno (Gari et al., 2012), para lo cual se utilizó el Digital Elevation Model (DEM) Shuttle Radar Topography Mission (SRTM) de 30m.

Mediante una máscara generada a partir del archivo vectorial con los límites establecidos de la Reserva, se recortó la imagen óptica y el mosaico de las imágenes radar.

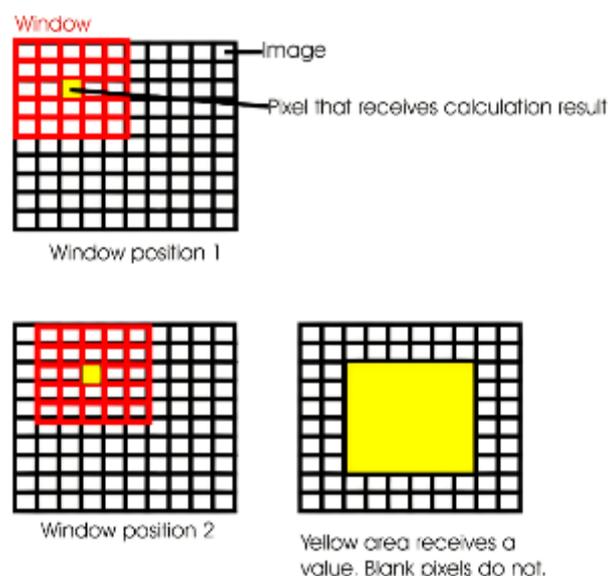
Una vez obtenido el recorte correspondiente a la zona de estudio, se realizó el análisis textural de las imágenes de radar. Este consiste en la aplicación de filtros de textura basados en una matriz de coocurrencia denominada Grey Level Co-occurrence Matrix (GLCM).

Las imágenes texturales muestran: 1. Diferencias de nivel de gris entre píxeles (contraste), 2. Tamaño definido del área donde se produce el cambio (vecindario, definido por un tamaño de ventana) y 3. Direccionalidad, o falta de ella (omnidireccional).

El análisis textural es un método que se suele utilizar para generar bandas adicionales que mejoren la precisión en los procesos de clasificación digital de imágenes. Haralick, Shanmugan y Dinstein (1973) se refieren a esto como una "matriz de dependencia espacial en tonos grises". Su implementación considera cuatro direcciones (0° , 45° , 90° y 135°) entre celdas vecinas que están separadas por cierta distancia. Habitualmente se han empleado tres aproximaciones para la obtención de información textural (Benediktsson y Sveinsson, 1997): 1. Estadísticos clásicos (desviación típica). 2. Índices de textura derivados de la matriz de concurrencias. 3. Función semivariograma. En general, se considera a la primera opción la más limitada (Berberoglu et al., 2007), mientras que la tercera es la más utilizada en ciencias de la Tierra. El uso de semivariogramas en teledetección se ha hecho siguiendo dos aproximaciones (Atkinson y Lewis, 2000): 1. Cálculo del semivariograma experimental para distancias relativamente cortas utilizando dichos valores como nuevas bandas. 2. Obtención de una capa de los parámetros de un modelo teórico de semivariograma ajustado a partir de los respectivos semivariogramas teóricos para cada uno de los píxeles.

La matriz está normalizada y por ende puede interpretarse como una medida de la probabilidad de aparición de dos niveles de gris separados por una distancia determinada en una dirección determinada. La imagen de texturas se calcula siguiendo los pasos: 1. Definición de la ventana (cuadrada y de número impar), 2. Cálculo y normalización de la GLCM para esa ventana, 3. Cálculo de la medida de textura elegida, 4. Ubicación del resultado sobre el píxel central de la ventana y 5- Cálculo sobre toda la imagen (Figura 5).

Figura 5. Cálculo de la GLCM de una imagen, ejemplo de una ventana de 5x5.



Los canales de textura generados a partir de las bandas de la imagen radar se pueden clasificar en tres grupos de acuerdo con sus características texturales (Tabla 3).

Tabla 3. Canales texturales

Grupo de contraste	Grupo de orden	Grupo de estadísticas
Contraste	Segundo Momento Angular (ASM)	GLCM Media
Disimilaridad	Máxima probabilidad (MAX)	GLCM Varianza
Homogeneidad	Entropía	GLCM Correlación

Cada textura modela distintas propiedades de la relación estadística de píxeles estimados según la co-ocurrencia dentro de una ventana que se va desplazando, en direcciones y distancias entre píxeles predefinidas.

Los píxeles suelen estar más correlacionados con los píxeles cercanos que con los píxeles más distantes (autocorrelación espacial). Por lo tanto, los tamaños de ventana más pequeños generalmente tendrán un valor de correlación más alto que las ventanas más grandes. La correlación es un cálculo diferente de las otras medidas de textura e independiente de ellas.

Las imágenes de textura pueden utilizarse en forma individual o con otros datos para definir firmas para la clasificación supervisada o no supervisada. Éstas pueden ser incluidas en las clasificaciones como bandas de la imagen a clasificar.

Se obtuvieron 8 bandas texturales y dos bandas radar originales correspondientes a las dos polarizaciones. A fin de disminuir la cantidad de información a procesar y seleccionar las bandas más relevantes, se realiza un análisis estadístico sobre las bandas texturales denominado Análisis de Componentes Principales (ACP). Debido a la forma en que se construyen las ecuaciones de textura, muchas de ellas están correlacionadas entre sí.

El ACP es una técnica que identifica redundancias y diferencias en una cierta cantidad de bandas y las transforma en nuevas bandas no correlacionadas (componentes principales) con un contenido de información maximizado. En consecuencia, el primer componente principal (PC1) representa la proporción máxima de varianza de las bandas originales. La variación restante se expresa mediante PC2, PC3, etcétera. Se espera que dicha reducción de dimensionalidad no produzca una pérdida importante de información. Desde este punto de vista, la técnica de reducción de la dimensión implica una consecuente ayuda en la interpretación de los datos. La PC1 contiene más información (sobre variabilidad) que la PC2, ésta a su vez más que la PC3 y así sucesivamente hasta no encontrar más variabilidad (Di Rienzo J. A et al., 2020).

Mediante el análisis de los autovalores y autovectores se puede verificar si las variables originales, en este caso las bandas texturales, están muy correlacionadas entre sí. En Tabla 4 de autovalores se observa que las primeras tres componentes reúnen un 98% de la información textural, por lo que se puede afirmar que la mayor parte de su variabilidad se puede explicar con estas componentes. Los autovectores indican los coeficientes con que cada variable original fue ponderada para conformar las PC 1 y 2, los de mayor peso corresponden a las variables Contrast, Correlation y Dissimilarity. Con el ACP se construyen ejes artificiales (PC) que permiten obtener gráficos de dispersión de observaciones y/o variables. En el biplot, los ángulos entre los vectores que representan las variables pueden ser interpretados en términos de las correlaciones entre variables. Ángulos de 90° entre dos variables indican que ambas variables no se encuentran correlacionadas. Alejamientos de este valor (tanto sea en valores menores como mayores a 90°) implican correlación (positiva o negativa). Es decir, un ángulo cercano a cero indica que ambas variables están fuertemente correlacionadas en

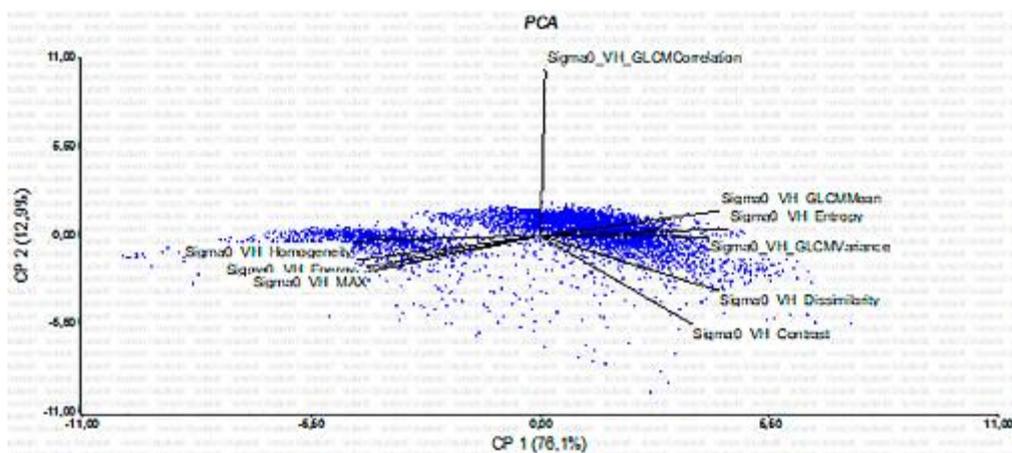
forma positiva y un ángulo cercano al ángulo llano entre dos variables muestran en ambas fuertes correlaciones negativas. (Di Rienzo J.A. et al.).

Tabla 4. Autovalores y autovectores de las bandas texturales

Autovalores				Autovectores		
Lambda	Valor	Proporción	Proporción acumulada	Variables	e1	e2
1	7,36	0,74	0,74	Sigma0_VH_Contrast	0,28	-0,52
2	1,36	0,14	0,87	Sigma0_VH_Dissimilarity	0,34	-0,32
3	1,06	0,11	0,98	Sigma0_VH_Homogeneity	-0,36	-0,10
4	0,10	0,01	0,99	Sigma0_VH_ASM	-0,33	-0,29
5	0,09	0,01	1,00	Sigma0_VH_Energy	-0,35	-0,23
6	0,02	1,7E-03	1,00	Sigma0_VH_MAX	-0,33	-0,29
7	0,01	9,8E-04	1,00	Sigma0_VH_Entropy	0,36	0,11
8	0,01	5,4E-04	1,00	Sigma0_VH_GLCMMean	0,34	0,04
9	3,5E-03	3,5E-04	1,00	Sigma0_VH_GLCMVariance	0,30	-0,14
10	6,3E-04	6,3E-03	1,00	Sigma0_VH_GLCMCorrelation	-0,10	0,60

En el gráfico (Figura 6) de las dos primeras componentes principales, se observa que la variable Correlation es ortogonal a los demás grupos de variables y la variable Contrast representa otra dirección, lo cual implica poca correlación con el resto de las variables. La variable Dissimilarity se la descarta por estar correlacionada con la variable Contrast y se selecciona como tercer componente principal la variable ASM a partir de los valores obtenidos en la matriz de correlaciones.

Figura 6. Gráfico biplot de las bandas texturales

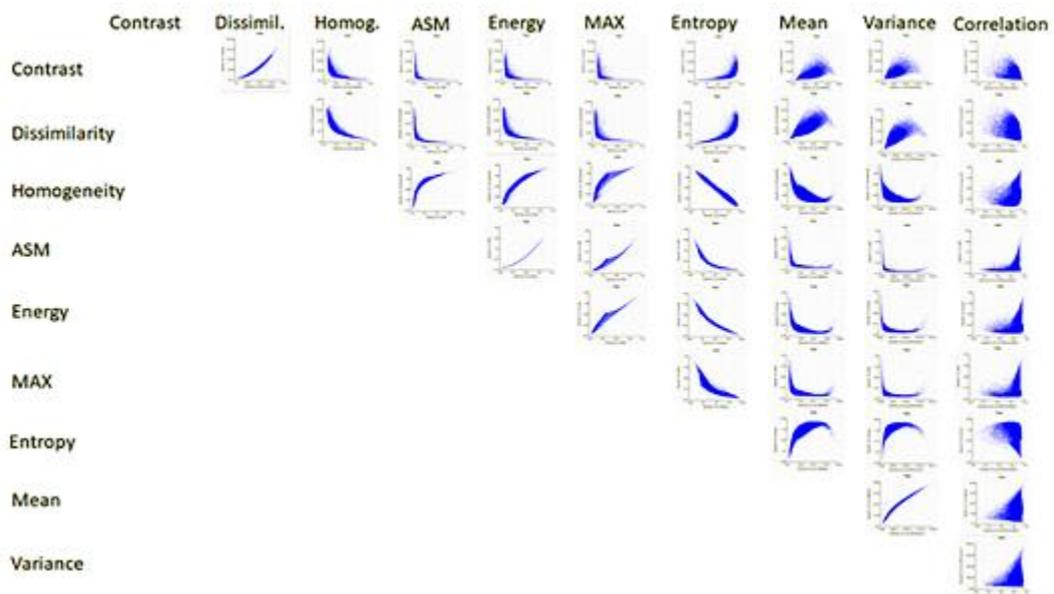


Asimismo, se obtiene la matriz de diagramas de dispersión que representa en un mismo gráfico las relaciones entre todos los pares de bandas disponibles (Figura 7). Los diagramas de dispersión describen el comportamiento de dos variables y se representan por una nube de puntos. Estos diagramas tienen en cuenta las relaciones entre pares de bandas donde cada punto tiene como coordenadas los valores digitales de cada píxel en cada una de las bandas consideradas. Mientras más dispersa sea la nube de puntos, menos correlacionadas estarán las bandas analizadas. Además, indica si la correlación es positiva o negativa. Se observa que las bandas antes seleccionadas reúnen

datos dispersos respecto a las demás y representan al conjunto de bandas texturales. Las bandas de media o varianza muestran gráficos dispersos, se descartó la utilización de estas debido a que los valores de correlación son menores y a que disminuye la separabilidad de clases en la clasificación. Asimismo, del diagrama entre contraste y disimilaridad, se denota la fuerte correlación entre ambas variables, por lo cual solo una se selecciona como información relevante.

Figura 7. Matriz de diagramas de dispersión de las bandas texturales

Bandas	Ener	MAX	Entro
Contrast	0	0	0
Dissimilarity	0	0	0
Homogeneity	0	0	0
ASM	0	0	0
Energy	1	0	0
MAX	0,97	1	0
Entropy	-0,97	-0,91	1
GlcM M	-0,79	-0,72	0,86
GlcM V	-0,62	-0,54	0,72
Sigma0 VH	0,19	0,15	-0,23



A partir de la matriz de correlaciones de Pearson se puede identificar el grado de relación lineal entre pares de variables de forma numérica. La misma indica la dependencia lineal entre dos variables o bandas. (Tabla 5).

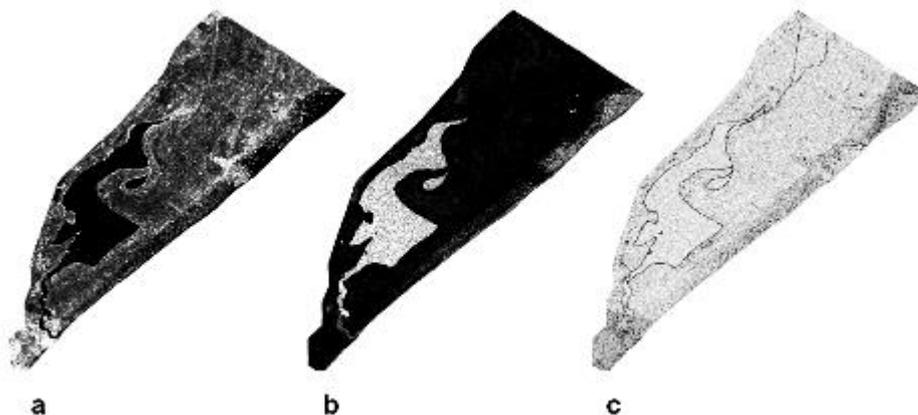
Tabla 5. Matriz de correlaciones de Pearson de las bandas texturales

Bandas	Contra	Diss	Homo	ASM
Contras	1	0	0	0
Diss	0,94	1	0	0
Homo	-0,63	0,84	1	0
ASM	-0,43	-0,65	0,91	1
Energy	-0,52	-0,74	0,97	0,97
MAX	-0,44	-0,66	0,91	0,98
Entropy	0,63	0,84	-0,90	-0,91
GlcM M	0,70	0,84	-0,85	-0,71
GlcM V	0,77	0,84	-0,71	-0,53
Sigma0VH	-0,50	0,44	0,24	0,18

Bandas	GLCM M	GLCM V	SIGMA 0 VH
Contrast	0	0	0
Dissimilarity	0	0	0
Homogeneity	0	0	0
ASM	0	0	0
Energy	0	0	0
MAX	0	0	0
Entropy	0	0	0
GlcM M	1	0	0
GlcM V	0,95	1	0
Sigma0 VH	0,01	-0,02	1

A partir del análisis de estos resultados se seleccionaron las bandas de textura, considerando aquellas menos correlacionados entre sí: Contraste, SMA y Correlación. (Figura 8).

Figura 8. Bandas texturales (a) Contraste, (b) SMA y (c) Correlación



En base a técnicas de análisis visual y trabajos de investigación y de campo, se caracterizaron los diferentes ambientes presentes en el área de estudio y se identificaron 8 clases temáticas: cortaderal, espartillar, pastizal salobre, juncal, vegetación psamófila, lagunas y bañados, médano vivo y playa y forestal (Figura 9).

Figura 9. Fotos de los diferentes ambientes



1. Cortaderal: La especie dominante es la cortadera (*Cortaderia selowiana*) y es acompañada por otras especies tales como: *Bromus auleticus*, *Juncus acutus*, *Eryngium eburneum*, *Senecio selloi*, *Melilotus albus*, *Adesmia incana*, etc.

2. Espartillar: Es un ambiente bajo. La especie dominante es la espartina (*Spartina densiflora*), y a diferencia de otros espartillares es menos salino, con especies como *Bromus auleticus*, *Deyeuxia viridiflavescens*, etc.

3. Pastizal salobre: Son pastos altos en suelos inundables y salobres con predominio de *Stenotaphrum secundatum*, *Distichlis spicata* y *D. scoparia*. También se encuentran presentes espartillares y juncales, espartillar (*Spartina densiflora*) y el junco (*Juncus acutus*), acompañadas de *Salicornia ambigua*.

4. Juncal: Se presentan en zonas intermedanasas semi-inundables por aguas salobres. La especie dominante es el junco (*Juncus acutus*), alcanza entre 80 y 150 cm de altura, son plantas robustas y crecen en matas densas. Está acompañado por especies herbáceas de porte bajo y hojas carnosas, como el heliotropo, el jume, la verdolaga, etc.

5. Vegetación psamófila: Sobre los terrenos arenosos del cordón costero, limitando la playa y el cortaderal, se desarrolla la vegetación psamófila, Es típica de este ambiente la *Spartina ciliata*, suele estar acompañada de otras especies como *Calycera crassiflora*, muy frecuente en las costas bonaerenses y *Senecio crassiflorus*, también abundante. Posee una baja cobertura (20-30%) y un ancho de aproximadamente 100 a 150 metros. Estos pastizales soportan vientos fuertes, falta de agua, salinidad y altas temperaturas.

6. Laguna y bañados: la laguna está representada por la albufera dispuesta paralela al mar, de aguas salobres, separada por una cadena de médanos y unida al mar por una boca. En los bañados predominan las especies: *Schoenoplectus californicus* y en menor cantidad *Zizaniopsis bonariensis*, *Solanum galucophyllum*. En los lugares más profundos se destacan *Myriophyllum platinoide*s y *Potamogeton striatum*. En lugares de aguas someras se desarrollan hidrófilas flotantes como *Spirodela intermedia*, *Lemma valdiviana*, *Azolla filiculoides*, etc. (Iribarne, 2001).

7. Médano vivo y playa: Corresponde a la zona litoral con playas de arena y la presencia de dunas anteriores, intermedias y posteriores. La vegetación es rala con especies tales como: *Panicum racemosum*, *Distichlis scoparia*, *Ambrosia tenuifolia* y *Bromus unioloides*.

8. Forestal: Hay formaciones pequeñas de talaes (*Celtis tala*), que se extienden a lo largo de la costa bonaerense. En zonas urbanizadas se observan plantaciones de *Eucalyptus spp.* y *Pinus spp.*

Para la clasificación supervisada de la imagen óptica, como así también para la imagen generada utilizando las bandas de la imagen óptica, las dos bandas de radar (polarización VV y VH) y las tres bandas texturales (Contraste, Correlación y SMA), se utilizó el algoritmo de Random Forest, de aprendizaje automático que ajusta iterativamente los modelos de árbol de regresión a subconjuntos aleatorios de los datos de entrada y utiliza el resultado combinado para la predicción (Cutler et al., 2007). Es decir, un modelo Random Forest está formado por un conjunto de árboles de decisión individuales, cada uno entrenado con una muestra ligeramente distinta de los datos de entrenamiento generada mediante (validación cruzada, k-iteraciones). La predicción de una nueva observación se obtiene agregando las predicciones de todos los árboles individuales que forman el modelo.

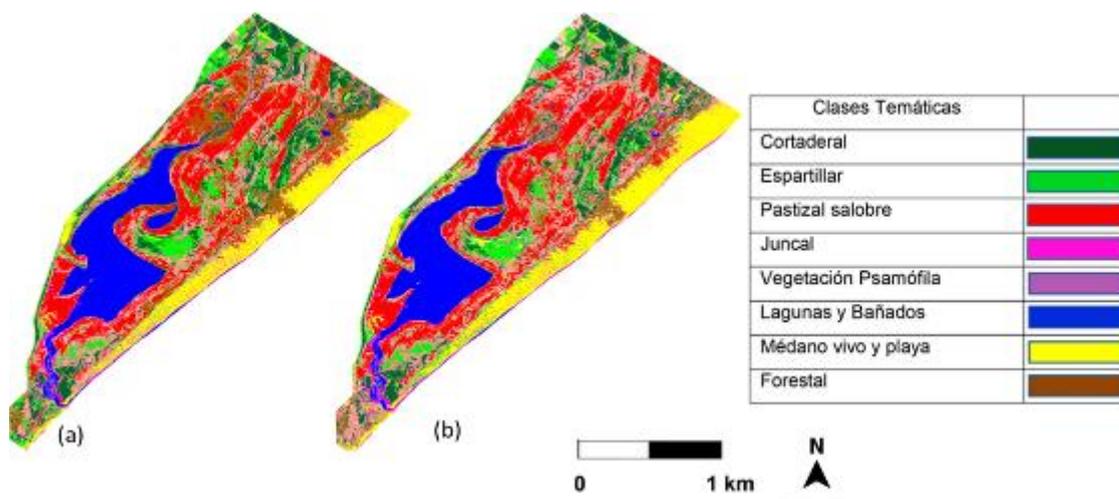
Random Forest (Breiman, 2001) es un metaclassificador que utiliza árboles de decisión como clasificadores base, donde cada clasificador contribuye con un voto para la asignación de la clase más frecuente. Un árbol de decisión se construye mediante sucesivas particiones binarias del conjunto de datos de entrenamiento en subconjuntos (nodos) de homogeneidad creciente. La homogeneidad se mide con el índice de Gini (G) (Breiman et al., 1984) que se reduce al mínimo cuando todas las observaciones pertenecen a la misma clase. En cada paso, el nodo con mayor valor de G se divide en función de que los valores de sus celdillas para una determinada variable superen o no un determinado umbral. Dicho umbral y variable se seleccionan para minimizar el valor de G en los nodos resultantes. El proceso continúa hasta que ninguna subdivisión puede reducir más el índice de Gini (Cutler et al., 2007). El resultado final debe ser un árbol de clasificación cuyos nodos finales se etiquetan en función de la clase predominante siendo el resto de los casos errores de clasificación. A partir de estos errores es posible podar el árbol para darle mayor capacidad de generalización. Un árbol así generado puede utilizarse después para clasificar nuevos casos.

Random Forest produce muy buenos resultados en comparación con otros sistemas de clasificación basados o no en árboles de decisión (Breiman, 2001; Liaw y Wiener, 2002).

3. Resultados

A la imagen óptica y a la imagen generada de 14 bandas se les aplicó una clasificación multibanda, obteniéndose mapas temáticos con las clases correspondientes a: Cortaderal, Espartillar, Pastizal salobre, Juncal, Vegetación Psamófila, Lagunas y bañados, Médano vivo y playa y Forestal (Figura 10 a y b).

Figura 10. Mapas temáticos (a) imagen óptica, (b) imagen óptica-radar.



Con relación a las estadísticas de clases (Tabla 6) la imagen compuesta (óptica – radar) tiene un mejor ajuste en las clases pastizal salobre y forestal.

Tabla 6. Estadística de clase

Clases	Clasificación imagen óptica	Imagen óptica, radar y texturales
Cortaderal	12,322%	11,511%
Espartillar	7,642%	6,819%
Pastizal salobre	19,658%	24,554%

Juncal	1,463%	1,595%
Vegetación Psamofila	20,633%	21,989%
Lagunas y bañados	16,317%	16,390%
Médano vivo y playa	10,713%	12,199%
Forestal	11,252%	4,942%

Al analizar los valores de Kappa y Overall accuracy (Tabla 7) de ambas clasificaciones, la imagen compuesta (óptico–radar) presentó mejores resultados.

Tabla 7. Valores Kappa y Overall accuracy

Imágenes	Kappa Coefficient	Overall accuracy
Óptica	0,8369	89,0932 %
Ópticas-Radar	0.8507	90.0219 %

4. Conclusiones

La metodología empleada resultó satisfactoria dado que la clasificación realizada combinando datos ópticos y de radar junto con algoritmos de aprendizaje automático, como Random Forest (RF) y seleccionando como clases temáticas las diferentes comunidades de vegetación presentes en la reserva, demostró que la capacidad de discriminación e identificación de los pastizales autóctonos, mejora notablemente que empleando datos ópticos únicamente.

Una de las ventajas del método RF es que se basa en unos pocos parámetros de entrada y provee resultados de clasificación bastante precisos. Esta precisión depende también de la elección de los sitios de entrenamiento, por lo que podría mejorarse utilizando imágenes de mayor resolución espacial.

La clasificación de imágenes compuestas por datos ópticos y bandas texturales derivadas de datos radar permiten utilizar las características de cada sensor y combinarlas obteniendo una mejora en la precisión de la clasificación.

Los métodos de adquisición de datos a través de sensores ópticos y de microondas reaccionan de manera diferente con relación a las distintas cubiertas terrestres y, por lo tanto, brindan información altamente complementaria.

Los canales texturales derivados de la imagen Sentinel 1 más pertinentes para la clasificación, fueron Contraste, Segundo Momento Angular y Correlación.

Los resultados presentan una mejor precisión en la discriminación de clases con respecto a los obtenidos en un trabajo previo, donde sólo se utilizaron datos ópticos provenientes de los satélites Landsat 5 y 8, SPOT 7 y Sentinel 2.

La combinación de datos ópticos y SAR permitió una mejor discriminación entre las clases Pastizal salobre, Vegetación psamófila y Forestal. Esta última fue sobreestimada al clasificarla con datos ópticos.

Con relación a las clases de vegetación analizadas predominan en la reserva las correspondientes al Pastizal salobre y a la Vegetación psamófila. En cuanto a los pastos altos, la clase Cortaderal ocupa la

mayor superficie, quedando relegado los Juncales a los manchones que se generan en las zonas bajas y con mayor presencia de agua.

Uno de los beneficios clave que ofrece el uso de imágenes de Sentinel es que tanto los datos de radar SAR como las imágenes multispectrales están disponibles de forma gratuita y pueden procesarse en el programa gratuito SNAP.

Obtener información temática precisa en un área con un paisaje heterogéneo pero que presenta clases espectralmente similares es todo un desafío, de allí la importancia de este tipo de estudios.

Dado que Mar Chiquita es un humedal de extraordinaria importancia para el país y a nivel mundial, resulta esencial fortalecer las iniciativas de conservación de la biodiversidad, uso racional de los recursos y rescate del patrimonio cultural.

Como conclusión final se destaca la importancia del uso de estas tecnologías como fuente de información continua que debe ser complementadas con información de relevamiento de campo.

Referencias bibliográficas

Antes, M.; Cuello, A; Ortone, A. y L. Cook (2020). Teledetección y SIG aplicados al monitoreo de la reserva natural de la defensa campo Mar Chiquita Dragones de Malvinas. 2017 *Revista GeoSIG* 1852-8031, PRODISIG. INIGEO. UNLu

Atkinson, P.M. y Lewis, P. (2000). Geostatistical classification for remote sensing. An introduction. *Computers and Geosciences*, 26, 361-371

Benediktsson, J.A. y Sveinsson, J.R. (1997). Feature extraction for multisource data classification with artificial neural networks. *International Journal of Remote Sensing*, 18, 727-740

Berberoglu, H.; Yin, J. y Pilon, L. (2007). Texture classification of Mediterranean land cover. *Rev. International Journal of Applied Earth Observation and Geoinformation*, 9, 322-334. 346

Breiman, J. (2001). Random Forest. *Machine Learning*, 45, 5-32

Breiman, L.; Friedman, J.; Stone, Ch. and R.A. Olshen. (1984). *Classification and Regression Trees*. SBN 9780412048418. Published Chapman and Hall/CRC

Cuello A.; Díaz, M.; Antes M. y L. Di Franco. (2011). Variables de paisaje en el monitoreo ambiental de la Reserva Natural de la Defensa Campo Mar Chiquita, Provincia de Buenos Aires, III Jornadas Argentinas de Ecología de Paisajes, San Carlos de Bariloche, Argentina, Revista de la Asociación Argentina de Ecología de Paisajes, ISSN 1853-8045, RASADEP, Volumen 2, Número 2, pp. 27-35

Cutler, D.; Edwards, T.C.; Beard, K.H.; Cutler, A.; Hess, K.T.; Gibson, J. y J.J. Lawler. (2007). Random Forest for classification in ecology. *Ecology* 88 (11), 2783–2792

Di Rienzo J.A.; Casanoves F.; Balzarini M.G.; González L.; Tablada M. y C.W. Robledo. InfoStat versión 2020. Centro de Transferencia InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. URL <http://www.infostat.com.ar>

Ellis, E. C.; Klein Goldewijk, K.; Siebert, S.; Lightman, D. and N. Ramankutty. (2010). Anthropogenic transformation of the biomes, 1700 to 2000. *Global Ecology and Biogeography* 19(5):589–606 <http://glcfapp.umiacs.umd.edu:8080/esdi/index.jsp>

Gari, J.; Cuello, A.; Sedeño, A.; Ortone, A. y A. Gari. (2012). Mapa temático de la zona del Glaciar Perito Moreno utilizando información de sensores ópticos y de radar. Memorias Sexto Congreso de la Ciencia Cartográfica. Bs. As., Argentina

Haralick, R.; Shanmugan, K. and Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics* 3, no. 6 (1973): 610-621

Hill, M.J.; Ticehurst, C.J.; Lee J.S; Grunes, M.R.; Donald, G.E. and D. Henry. (2005). Integration of optical and radar classifications for mapping pasture type in Western Australia. *IEEE Transactions on Geoscience and Remote Sensing*. Volume: 43 Issue: 7, 1665 – 1681. INSPEC Accession Number: 8525371 DOI: 10.1109/TGRS.2005.846868

Iribarne, O. (2001). Reserva de Biosfera Mar Chiquita: Características físicas, biológicas y ecológicas. Editorial Martín con apoyo de la Oficina Regional de Ciencia y Tecnología de la UNESCO para América Latina y el Caribe, de la Universidad Nacional de Mar del Plata y de la Fundación Antorchas. Mar del Plata. Argentina.

Kaplan, G. J. & U. Avdan. (2018). Sentinel-1 and Sentinel-2 data fusion for wetlands mapping: Balıkdami, Turkey. doi: 10.5194/isprs-archives-xlii-3-729-2018

Liaw, A. and Wiener, M. (2002). Classification and Regression by Random Forest. *R News*, 2, 18-22.

Maceira, N. O.; Zelaya, D. K.; Celemin, J. P. y Fernández, O. N. (2005). Uso de la tierra y elementos para el mejoramiento y la sustentabilidad de la Reserva de la Biósfera de Mar Chiquita, provincia de Buenos Aires

Montesano, P.M; Cook, B.D.; Sun, G.; Simard, M.; Nelson, R.F; Ranson, K.J.; Zhang, Z. y S. Luthcke (2013). Achieving accuracy requirements for forest biomass mapping: A spaceborne data fusion method for estimating forest biomass and LiDAR sampling error. *Remote Sensing of Environment*, 130: 153-170

Neiff, J.J.; Casco, S.L y J.C. Arias. (2004). Glosario de humedales de Iberoamérica. 336-380. en: Neiff, J.J. (Ed.). *Humedales de Iberoamérica. CYTED, Subprograma XVII*. Red Iberoamericana de Humedales. Cuba. ISBN: 959-270-036-2. 380 pp.

Peters, J.; Van Coillie, F.; Westra, T. & R. De Wulf (2011). Synergy of very high resolution optical and radar data for object-based olive grove mapping, *International Journal of Geographical Information Science*, 25:6,971989, DOI:10.1080/13658816.2010.515946

Reiche, J.; Verbesselt, J.; Hoekman, D. y M. Herold. (2015). Fusing Landsat and SAR time series to detect deforestation in the tropics. *Remote Sensing of Environment*, Volume 156, Pages 276-293

Rodrigues & Souza-Filho. (2011). Use of Multi-Sensor Data to Identify and Map Tropical Coastal Wetlands in the Amazon of Northern Brazil. *Wetlands* 31(1):11-23. DOI:10.1007/s13157-010-0135-6

Soriano, A. (1992). Río de la Plata grasslands. En: *Eco- systems of the world. Natural grasslands*. Introduction and western hemisphere (R. Cou- pland, Ed.). Elsevier. New York, USA. Pp.367-407

Ullmann, T.; Schmitt, A.; Roth, A.; Duffe, J.; Dech, S.; Hubberten, H and R. Baumhauer. (2014). Land Cover Characterization and Classification of Arctic Tundra Environments by Means of Polarized

Synthetic Aperture X- and C-Band Radar (PolSAR) and Landsat 8 Multispectral Imagery – Richards Island, Canada. *Remote Sens.* 2014, 6(9), 8565-8593; <https://doi.org/10.3390/rs6098565>
Wang, Y. (2010). *Remote Sensing of Coastal Environments* Taylor and Francis Serie, CRC

Zhou, Q. y M Robson (2001). Automated rangeland vegetation cover and density estimation using ground digital images and a spectral-contextual classifier. *International Journal of Remote Sensing*-Taylor & Francis

Sitios Internet consultados:

<http://marchiquita-online.es.tl/Reserva-de-Biosfera-Mar-Chiquita--Informaci%F3n>
<http://marpla.com.ar/fueron-detenido-15-cazadores-furtivos/>
http://obio.ambiente.gob.ar/reservas-de-biosfera_p1341
<http://prensamarchiquita.com.ar/operativo-exitoso-en-mar-chiquita-contra-cazadores-furtivos/>
<https://sib.gob.ar/index.html#!/areas-protegidas>
<http://step.esa.int/main/third-party-plugins-2/sen2cor/>
<http://step.esa.int/main/toolboxes/snap>
<http://www.ambiente.gov.ar/archivos/web/GTRA/file/ava>
<http://www.esa-landcover-cci.org/>
<http://www.marchiquitakitecenter.com>
<http://www.patrimonionatural.com/HTML/provincias/buenosaires/marchiquito/descripcion.asp->



Esta obra se encuentra bajo Licencia Creative Commons Reconocimiento-NoComercial 4.0. Internacional. Reconocimiento - Permite copiar, distribuir, exhibir y representar la obra y hacer obras derivadas siempre y cuando reconozca y cite al autor original. No Comercial – Esta obra no puede ser utilizada con fines comerciales, a menos que se obtenga el permiso.