



UNIVERSIDAD DE CUENCA

Facultad de Ingeniería

Maestría en Investigación en Ciencias de la Ingeniería para la Gestión de los Recursos Hídricos.

Caracterización SIG del uso de la tierra y geomorfología del Macizo del Cajas - Ecuador.

Trabajo de titulación previo a la obtención del título de Magister en Investigación en Ciencias de la Ingeniería para la Gestión de los Recursos Hídricos

Autora:

Ing. Civil Ana Ximena Caldas Calle.

CI: 0104359864

Correo electrónico: anice_842002@yahoo.com.mx

Director:

Ing. Raúl Fernando Vázquez Zambrano, PhD.

CI: 0102059441

Co-Director:

Biol. Julio Danilo Mejía Coronel, MSc.

CI: 0103638581

Cuenca – Ecuador

21-enero-2020



RESUMEN:

Con la intención de generar, mediante la teledetección, información útil para la gestión adecuada de los valiosos recursos naturales del sur del Ecuador, se presentan los resultados preliminares obtenidos a partir de la combinación de diversos productos de percepción remota, así como el tratamiento de imágenes satelitales Landsat 8. Este estudio está compuesto por tres análisis; Primero, se definió la cobertura vegetal y el uso de suelo en la Biosfera del Macizo del Cajas (MzC) - Ecuador, para lo cual, se emplearon tres métodos de clasificación supervisada: Máxima Verosimilitud (MV), Redes Neuronales Artificiales (ANN) y la Distancia de Mahalanobis (MH). En segundo lugar, se estimaron las profundidades de los principales lagos y lagunas del PNC (135), a través de la aplicación del algoritmo de Banda Única (BU), y por último se realizó el análisis de la correlación entre variables limnimétricas de los lagos y lagunas en el PNC (145) y las propiedades físicas de los contornos de estos lagos y lagunas, por medio del algoritmo de Análisis de Componentes Principales (ACP). Se evaluó el desempeño de cada uno de los algoritmos aplicados en este estudio, particularmente a través del error relativo absoluto, así como también, mediante el empleo de histogramas de frecuencias. La evaluación sugirió que para el estudio del uso/cobertura del suelo, el mejor producto de la clasificación de imágenes se obtuvo mediante el algoritmo de ANN. Por su parte, de los 135 lagos estudiados, 89 fueron clasificados como lagos someros y 46 como lagos profundos. En el tercer análisis, el ACP no sugiere una correlación aceptable entre las variables limnimétricas y las físicas de los contornos de los lagos y lagunas. Con base en estos resultados, el trabajo a futuro deberá incluir la revisión de los polígonos de entrenamiento (ROIs) empleados en la presente investigación, así como la posible reducción del número de clases consideradas, a fin de disminuir al mínimo los problemas de clasificación automática debido a la superposición de la respuesta espectral para el uso/cobertura del suelo.

Palabras claves: SIG. Teledetección. Imágenes multi-espectrales. Uso del suelo. Batimetría. Correlación.



ABSTRACT:

With the intention of generating through remote sensing useful information for the proper management of the valuable natural resources of southern Ecuador, the preliminary results obtained from the combination of various remote sensing products are presented, as well as the treatment of Landsat 8 satellite images. Three main analyses were carried out in this study: firstly, the vegetation cover and land use in the Cajas Massif Biosphere (MzC) - Ecuador was defined through the application of three supervised classification methods, namely, Maximum Likelihood (MV), Artificial Neural Networks (ANN) and Mahalanobis Distance (MH). Secondly, the depths of 135 lakes and lagoons of the Cajas Antional Park (PNC) were estimated, through the application of the Single Band algorithm (BU). Finally, the analysis of the correlation of limnimetric variables of 145 lakes and lagoons of the PNC and physical variables characterising the surrounding of these lakes and lagoons was performed through a Principal Component Analysis (ACP). The performance of each of the algorithms applied in this study was evaluated, particularly through absolute relative error, as well as through the use of frequency histograms. The evaluation suggested that for the study of land use/coverage, the best image classification product was obtained using the ANN algorithm. On the other hand, of the 135 lakes studied, 89 were classified as shallow lakes and 46 as deep lakes. In the third analysis, the ACP did not suggest an acceptable correlation between the limnimetric and physical variables of the contours of the lakes and lagoons. Based on these results, future work should include the review of the training polygons (ROIs) used in this investigation, as well as the possible reduction of the number of classes considered, in order to minimize the problems of automatic classification due to the superposition of the spectral response for land use/coverage

Keywords: GIS. Remote sensing. Multispectral images. Land use. Bathymetry. Correlation.



CAPÍTULO I: INTRODUCCIÓN	13
1.1 OBJETIVOS GENERAL Y ESPECÍFICOS.....	16
CAPITULO II: MATERIALES Y MÉTODOS	16
2.1 ÁREA DE ESTUDIO	16
2.2 INFORMACIÓN REMOTA DISPONIBLE	18
2.2.1 Información remota disponible para el Mapa de Uso/Cobertura de Suelo	18
2.2.2 Información remota disponible para el estudio de profundidades de lagos	19
2.2.3 Información disponible para el análisis de correlaciones entre variables limnológicas y morfo-métricas de lagos y lagunas en el PNC.....	21
2.3 PROCESAMIENTO PREVIO DE LAS IMÁGENES SATELITALES	22
2.3.1 Corrección Radiométrica.....	22
2.4 GENERACIÓN DEL MAPA DE USO/COBERTURA DEL SUELO PARA EL MZC	25
2.4.1 Método de Máxima Verosimilitud (MV).....	27
2.4.2 Método de la distancia de Mahalanobis (MH)	29
2.4.3 Método de Redes Neuronales Artificiales (ANN).....	29
2.4.4 Evaluación de los productos de los métodos de clasificación.....	31
2.5 ESTIMACIÓN DE LAS PROFUNDIDADES DE LAGOS Y LAGUNAS EN EL PNC	33
2.5.1 Evaluación del desempeño del algoritmo para la estima de la profundidad de los lagos del PNC.....	37
2.6 ANÁLISIS DE LA POSIBLE CORRELACIÓN ENTRE VARIABLES LIMNIMÉTRICAS DE LAGOS Y LAGUNAS EN EL PNC Y LAS CARACTERÍSTICAS MORFOLÓGICAS DE SUS ALREDEDORES	38
2.6.1 Tratamiento estadístico de datos por medio del Análisis de Componentes Principales (ACP).....	40
3 CAPITULO III: RESULTADOS	43
3.1 MAPA TEMÁTICO DE USO/COBERTURA DEL SUELO PARA EL MZC.....	43
3.1.1 Producto del método Redes Neuronales Artificiales (ANN)	43
3.1.2 Clasificador Máxima Verosimilitud (MV).....	45
3.1.3 Clasificador Mahalanobis (MH).....	46
3.1.4 Evaluación de la precisión de los clasificadores	47
3.1.5 Evaluación del clasificador de uso/cobertura de suelo Post-Clasificación.....	54
3.2 ESTIMA DE LA PROFUNDIDAD DE LAGOS Y LAGUNAS DEL PNC.....	58
3.2.1 Evaluación de la precisión de la estima de las profundidades	66
3.3 ANÁLISIS DE LA POTENCIAL CORRELACIÓN ENTRE VARIABLES LIMNIMÉTRICAS DE LOS LAGOS Y LAGUNAS DEL PNC Y LAS PROPIEDADES MORFOLÓGICAS DE LOS ALREDEDORES DE ESTOS CUERPOS DE AGUA	70



4	CAPITULO IV: DISCUSIÓN	82
4.1	MAPA DE USO/COBERTURA DEL SUELO DEL MACIZO DEL CAJAS (MzC)	82
4.2	ESTIMA DE LA PROFUNDIDAD DE LOS LAGOS Y LAGUNAS DEL PNC	82
4.3	ANÁLISIS DE LA POTENCIAL CORRELACIÓN ENTRE VARIABLES LIMNIMÉTRICAS DE LOS LAGOS Y LAGUNAS DEL PNC Y LAS PROPIEDADES MORFOLÓGICAS DE LOS ALREDEDORES DE ESTOS LAGOS Y LAGUNAS.....	83
5	CONCLUSIONES	85
5.1	GENERACIÓN DE UN MAPA DE USO/COBERTURA DEL SUELO EN EL MACIZO DEL CAJAS (MzC).....	85
5.2	ESTIMA DE LA PROFUNDIDAD DE LOS LAGOS Y LAGUNAS DEL PNC	86
5.3	ANÁLISIS DE LA POTENCIAL CORRELACIÓN ENTRE VARIABLES LIMNIMÉTRICAS DE LOS LAGOS Y LAGUNAS DEL PNC Y LAS PROPIEDADES MORFOLÓGICAS DE LOS ALREDEDORES DE ESTOS LAGOS Y LAGUNAS.....	86
6	REFERENCIAS	87
7	ANEXOS	91



Tabla 1. Información digital geográfica disponible para el desarrollo del mapa del uso/cobertura del suelo en el Macizo del Cajas (MzC). 18

Tabla 2. Información digital geográfica disponible para el mapa de uso de suelo. 25

Tabla 3. Variables Limnimétricos y morfológicas de los lagos, en el Parque Nacional Cajas (PNC). 38

Tabla 4. Parámetros de entrenamiento obtenidos en el análisis de sensibilidad aplicando el método de clasificación Redes Neuronales Artificiales (ANN) para el Macizo de Cajas (MzC). 44

Tabla 5. Número de píxeles en cada ráster medido de los métodos Redes Neuronales Artificiales (ANN), Máxima Verosimilitud (MV) y Mahalanobis (MH). 53

Tabla 6. Error relativo absoluto (ERA) calculado en base al número de píxeles medidos en función de los métodos Redes Neuronales Artificiales (ANN), Máxima Verosimilitud (MV) y distancia de Mahalanobis (MH). 53

Tabla 7. Error relativo absoluto (ERA) asociado a la aplicación del filtro Majority Filter (MJ) y el filtro resultante de la combinación de los procesos Sieve Classes (SC) Clump Classes (CC) sobre el producto del método de clasificación ANN. 56

Tabla 8. Coeficientes de atenuación y de efecto de fondo, así como, de la respectiva correlación asociada a la regresión lineal sobre las bandas del visible. 60

Tabla 9. Estadísticas de la Regresión Banda Azul 62

Tabla 10. Estadísticas de la Regresión Banda Roja. 62

Tabla 11. Análisis de la Varianza, Banda Azul. 62

Tabla 12. Análisis de la Varianza, Banda Roja. 63

Tabla 13. Marcas de clase para las profundidades del Histograma banda azul y banda roja. 66

Tabla 14. Grupo de Lagos bien clasificados, por el algoritmo de banda única (azul). 68

Tabla 15. Grupo de Lagos bien clasificados, por el algoritmo de banda única (roja). 69

Tabla 16. Principales estadísticos de los diferentes parámetros limnimétricos de los lagos. 70

Tabla 17. Valores de la varianza para cada CP. 74

Tabla 18. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro elevación. 75

Tabla 19. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro orientación. 77

Tabla 20. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro Pendiente. 78

ÍNDICE DE FIGURAS



Figura 1. Área de estudio: la Biosfera del Macizo del Cajas (MzC), Ecuador. 17

Figura 2. Información de control disponible para el Parque Nacional Cajas (PNC), Ecuador. 19

Figura 3. Mapa de control de los cuerpos de agua examinados de la biosfera del Macizo del Cajas (MzC). 20

Figura 4. Distribución espacial de los 145 lagos y lagunas y de la información puntual de control proporcionada por el Laboratorio de Ecología Acuática (LEA) de la Universidad de Cuenca (UC) y ETAPA EP. 21

Figura 5. Capturas de pantalla que muestra las bandas 2,5 y 6 de Landsat 8 OLI: (a) antes de la corrección atmosférica; y (b) luego de la corrección atmosférica. 25

Figura 6. Polígonos de entrenamiento para cada clase de uso/cobertura de suelo en la Biosfera del Macizo del Cajas. 27

Figura 7. Ilustración del enmascaramiento de los lagos y lagunas. Se empleó la información únicamente dentro del contorno de los lagos. 35

Figura 8. Producto del método de Redes Neuronales Artificiales (ANN) para el Macizo de Cajas (MzC). 45

Figura 9. Producto del método de Máxima Verosimilitud (MV) para el Macizo del Cajas (MzC). 46

Figura 10. Producto del método de distancia de Mahalanobis (MH) para la el Macizo de Cajas (MzC). 47

Figura 11. Información de Control del Parque Nacional Cajas (PNC) sin información de los polígonos que se emplearon durante el proceso de clasificación de imágenes. 48

Figura 12. Producto del método de Redes Neuronales Artificiales (ANN) para el Parque Nacional Cajas (PNC). 49

Figura 13. Producto del método de Máxima Verosimilitud (MV) para el Parque Nacional Cajas (PNC). 49

Figura 14. Producto del método de distancia de Mahalanobis (MH) para el Parque Nacional Cajas (PNC). 50

Figura 15. Producto de la cobertura de uso de suelo de la clase Cuerpos de Agua (CA) que se deriva del mapa de Control. 51

Figura 16. Producto de la cobertura de uso de suelo de la clase Cuerpos de Agua (CA) que se deriva del mapa obtenido por el método de RNA. 52

Figura 17. Producto de la diferencia del valor Absoluto (Control-ANN), para la cobertura cuerpos de agua (CA). 52

Figura 18. Producto del método de ANN, luego de la aplicación del filtro Majority Filter (MJ). 55

Figura 19. Producto del método de ANN, luego de la aplicación del filtro resultante de la combinación de los procesos Sieve Classes (SC) y Clump Classes (CC). 55

Figura 20. Validación y comprobación de resultados para el producto del método de ANN en relación a la clase “cuerpos de agua”. 58

Figura 21. La radiancia no transformada de la banda azul original de las imágenes satelitales capturadas de Lansat 8 OLI. 59

Figura 22. La radiancia transformada de la banda azul original de las imágenes satelitales capturadas de Lansat 8 OLI. 59

Figura 23. Diagrama de dispersión de los valores de radiancia de las bandas azul y roja. 60

Figura 24. Regresión entre las profundidades conocidas y la banda azul transformada. 61

Figura 25. Regresión entre las profundidades conocidas y la banda roja transformada. 61

Figura 26. Resultados de las profundidades de los lagos del PNC empleando la banda (azul). (a) Vista global; y (b) detalle de la región señalada en (a). La escala de colores es la misma en ambos casos. 64

Figura 27. Resultados de las profundidades de los lagos empleando la banda (roja), en el PNC. El marco rectangular muestra en la figura 30 a), detalla a mayor escala los resultados. En la figura 30 b). Se debe tener en cuenta que el mismo código de color se ha aplicado en ambas figuras. 65

Figura 28. Histograma de profundidades obtenidas por el algoritmo de banda única (banda azul). 67

Figura 29. Histograma de profundidades obtenidas por el algoritmo de banda única (banda roja). 68



Figura 30. Gráficos de dispersión entre profundidad máxima de los lagos versus variables morfológicas calculadas en el buffer de 500 m de ancho: (a) elevación media; (b) orientación media (aspecto); y (c) pendiente media. 72

Figura 31. Curva de referencia del error, del parámetro elevación. 73

Figura 32. Curva de referencia del error, del parámetro orientación (aspecto). 73

Figura 33. Curva de referencia del error, del parámetro pendientes. 73

Figura 34. PCA de las variables morfológicas con respecto a la Altitud. 80

Figura 35. PCA de las variables morfológicas con respecto al aspecto del alrededor de los lagos. 81

Figura 36. PCA de las variables morfológicas con respecto a la pendiente del alrededor de los lagos. 81



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Ana Ximena Caldas Calle en calidad de autora y titular de los derechos morales y patrimoniales del trabajo de titulación "Caracterización SIG del uso de la tierra y geomorfología del Macizo del Cajas - Ecuador", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 21 de Enero 2020

Ana Ximena Caldas Calle

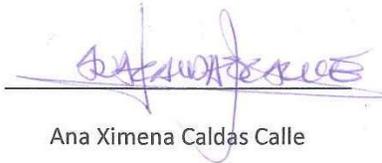
C.I: 0104359864



Cláusula de Propiedad Intelectual

Ana Ximena Caldas Calle, autora del trabajo de titulación "Caracterización SIG del uso de la tierra y geomorfología del Macizo del Cajas - Ecuador", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autora.

Cuenca, 21 de enero 2020



Ana Ximena Caldas Calle

C.I: 0104359864



DEDICATORIA

A Dios, por su infinita misericordia.

A la memoria de María Sacramento, Abuelita te llevo en mi corazón.

A mi hermano Luis Alberto, un guerreo en la inmensa batalla de la vida.

A mis padres y hermanos, por enseñarme el camino de la superación.

La sonrisa luego de recordar,

El suspiro luego de olvidar,

El placer de lograr un sueño, Tú.

A mi esposo Edi, por su amor incondicional,

Tú y Yo hasta el fin.



AGRADECIMIENTOS

El presente trabajo condensa un componente de la investigación llevada a cabo en el contexto de los proyectos dirigidos por el Dr. Raúl Vázquez Z.: "Uso de teledetección para el desarrollo de herramientas para la gestión de los recursos naturales del Parque Nacional Cajas (TeleAndes)", financiado por la Dirección de Investigación de la Universidad de Cuenca (DIUC); y (ii) "Water Management and Climate Change in the Focus of International Master Courses (WATERMAS)", financiado por la Agencia Europea "Education, Audiovisual and Culture Executive Agency (EACA)". Esta disertación refleja solo las opiniones de la autora; por lo tanto, ni la Unión Europea ni EACA son responsables del uso que pueda hacerse de la información contenida en este documento ("This dissertation reflects only the author's views; thereby, neither the European Union nor EACA is liable for any use that may be made of the information contained herein"). La autora agradece a la Empresa Pública Municipal de Telecomunicaciones, Agua Potable, Alcantarillado y Saneamiento de la ciudad de Cuenca (ETAPA EP.) por facilitar la información de control del Parque Nacional Cajas (PNC).

Un Agradecimiento especial al Dr. Raul Vázquez, por compartir sus conocimientos y por brindar un paciente seguimiento a este trabajo de grado.



CAPÍTULO I: INTRODUCCIÓN

El Macizo del Cajas (MzC) está dentro de la red mundial de reservas de Biosferas. Este posee la particularidad de la transición de alturas, cuyo inicio va desde el Golfo de Guayaquil a 0 metros sobre el nivel medio del mar (m s.n.m), hasta alcanzar al Parque Nacional Cajas (PNC) en los 4500 m s.n.m (Rodríguez Girón *et al.*, 2015). En el MzC existen alrededor de 6000 cuerpos de agua (lagos y lagunas), de los cuales más del 50% están dentro del PNC (Van Colen *et al.*, 2017). Estos forman una parte fundamental en la regulación hídrica de ríos que abastecen de agua potable a varias ciudades, tales como Cuenca, Azogues y Girón. Además, los cuerpos de agua drenan hacia las estribaciones occidentales y orientales, siendo fuentes importantes de riego para las zonas bajas (Empresa Municipal de Telecomunicaciones, Agua Potable y Saneamiento Ambiental de Cuenca [ETAPA EP], 2018) y son las nacientes de los principales afluentes de los ríos Tomebamba, Mazán, Yanuncay y Migüir, que aportan al complejo Hidroeléctrico Paute (Hidropaute, 2009).

Por tanto, es fundamental contar con un adecuado sistema de gestión de los importantes recursos naturales y servicios ambientales del MzC que debería estar basado en información adecuada de sus características físicas, ambientales y ecológicas. Sin embargo, la investigación científica escasea en este ámbito e incluso para algunas zonas del MzC, es nula (Hampel, Cocha y Vimos, 2010). Por otro lado, la exigua información que está disponible es bastante limitada en su resolución y variación espacial (Mosquera *et al.*, 2017).

En este marco, estudios pioneros tales como Mosquera *et al.* (2017) lograron obtener información científica muy relevante para la gestión de un componente esencial del MzC, el PNC, particularmente sobre la limnología de dos centenares de lagos y de varias propiedades físico-químicas asociadas, pero a un coste, sobre todo físico, muy importante, en particular por la falta de un financiamiento adecuado y lo remoto del área de estudio. Esto supuso un desgaste físico importante para el equipo investigador, trabajando arduamente por espacio de un año y medio, y en condiciones climáticas muy difíciles, a una elevación superior a los 3500 m s.n.m.

Por consiguiente, contar con información aceptable sobre la cobertura vegetal y el uso de suelo, la profundidad máxima de lagos profundos y someros del MzC, los tiempos de residencia de los cuerpos de agua del MzC, etc., en base a costes mínimos tanto físicos como monetarios, aplicando técnicas de teledetección, puede jugar un rol importante en el desarrollo local y regional (Sistema de Información Pública Agropecuaria [SIPA], 2016).

Los sensores satelitales captan información sobre la cobertura terrestre a partir de la radiación electromagnética proveniente de la luz solar y que es reflejada por la tierra, a ello se suma la energía dispersada y reflejada por la



atmósfera, lo cual mediante métodos matemáticos puede ser estimada y almacenada en matrices numéricas de escala artificial, conocidos como Números Digitales (ND). (Aguilar Arias *et al.*, 2014)

En este contexto, el empleo conjunto de métodos robustos de interpretación digital de imágenes satelitales y de Sistemas de Información Geográfica (SIG) tiene el potencial de obtener productos realmente útiles para la gestión y conservación de la biodiversidad (Arenas, Haeger y Jordano, 2011; Sun y Schulz, 2015), cubriendo rangos espaciales significativos y prácticamente en tiempo real (Chuvieco Salinero, 2006). Además, con el reciente desarrollo tecnológico de los sensores remotos, el volumen de imágenes satelitales sigue creciendo y su resolución tanto espacial como temporal mejora continuamente (Simone, Farina, Morabito, Serpico, y Bruzzone, 2002; Dukatz, Ferrati, y Canziani, 2006).

Así, métodos como las Redes Neuronales Artificiales (ANN) han ganado popularidad en el campo de clasificación (Ellah *et al.*, 2015), debido a su adaptabilidad y a su capacidad para producir resultados de alta precisión (Aziz *et al.*, 2017). Kavzoglu y Mather (2003) usaron ANN para la clasificación de imágenes, determinando valores óptimos de los parámetros principales de la red neuronal y efectuando una comparación de la calidad de los productos de los métodos ANN y de Máxima Verosimilitud (MV) (Tan *et al.*, 2011). Los resultados sugirieron que el método de ANN, con los ajustes recomendados, pueden producir una mayor precisión de clasificación que los de MV (Frinelle and Moody, 2001).

Por otro lado, de Oliveira Duarte, Zanetti, Junior, y das Graças Medeiros (2018) realizaron comparaciones entre los métodos de clasificación de Paralelepípedo, Promedio de Distancia Mínima (Felicísimo and Cuartero, 2009), MV y ANN, evaluando el rendimiento de cada uno, para obtener cartografía de cobertura de uso de suelo. Los mejores resultados se obtuvieron para el clasificador ANN. Del mismo modo, Richards y Jia (2006), Willington, Nolasco, y Bocco (2013), Paola y Schowengerdt (1995) utilizaron metodologías tales como ANN, MV y Distancia de Mahalanobis (MH) (Tso and Mather, 2009), obteniendo resultados alentadores de clasificación de imágenes satelitales mediante los métodos indicados.

En relación a la estima de las profundidades de lagos a través de la teledetección, los métodos más utilizados para su estimación son los de regresión lineal, y están basados en el hecho de que la profundidad a la que penetra la energía depende de la longitud de onda (Ceyhun y Yalçin, 2010).

El algoritmo de Banda Única (BU), es el algoritmo más comúnmente utilizado para la recuperación de la profundidad (Figueiredo *et al.*, 2016) y supone que la reflectividad en una imagen de banda única se correlaciona linealmente con las profundidades del agua en esa imagen (Gholamalifard, Kutser, Esmaili-Sari, Abkar, y Naimi., 2013). Además, este método permite aprovechar al máximo la longitud de onda visible más corta, la banda azul



por ejemplo, disponible en el espectro de las imágenes de Landsat 8, debido a que la máxima transmitancia de la energía en agua libre de materiales ocurre en el rango de 0.44 a 0.54 μm .

La reflectancia de los cuerpos de agua no mantienen una relación directa con la profundidad debido al efecto exponencial del coeficiente de atenuación de la energía (Hoepffner y Zibordi, 2009). Sin embargo, este método considera que el coeficiente de atenuación es constante y por lo tanto no requiere de información relacionada (columna de agua, propiedades de la atmósfera, material de fondo, etc.), aunque este aspecto reduce su precisión.

Adicionalmente, se han desarrollado otros métodos para la estimación de las profundidades tomando en cuenta las condiciones locales de los cuerpos de agua, el coeficiente de atenuación de la luz, el tipo de fondo, la turbidez, las propiedades de la atmósfera, etc. (Lyzenga, 1981; Fonstad y Marcus, 2005; Leu y Chang, 2005; Louchard et al., 2003). Sin embargo, la mayoría de estos métodos son difíciles de aplicar y en algunos casos solo sirven para condiciones específicas, demostrando así algunas limitaciones en cuanto a su aplicabilidad.

Mosquera et al. (2017) presenta un estudio geomorfológico, con base en las múltiples mediciones tomadas in-situ en el PNC, definiendo dos grupos marcadamente diferentes de relaciones entre parámetros geomorfológicos (p.ej., área y volumen de un lago) y la profundidad de los lagos en función de si estos son someros o profundos. Esto implica que, en el PNC, lagos con áreas superficiales muy parecidas pueden tener profundidades muy distintas (someras o profundas). Este aspecto se desmarca de la relación mundialmente aceptada como única entre parámetros geomorfológicos y la profundidad; por lo que resulta muy interesante investigar la posible relación entre los parámetros geomorfológicos principales de los entornos de los lagos y de la profundidad de los mismos con la intención de encontrar alguna explicación del por qué los lagos con áreas similares pueden tener volúmenes muy discrepantes.

Así, Quirós (2004) y Parra et al. (2003) han reconocido importantes correlaciones entre la morfología de un lago y su limnología, las mismas que servirían para predecir información únicamente mediante parámetros derivados de mapas. En la investigación desarrollada por (Castillo Jurado, 2004) se pudo realizar una caracterización geomorfológica, a través de un análisis de correlación de variables tales como las formas y tamaños de los lagos, para ello utilizó información como fotografías aéreas e imágenes satelitales, encontrando correlaciones significativas entre estas variables, mismas que indicaron patrones entre el comportamiento del lago y sus componentes. En el estudio de (Vega, Hoyos, Aldasoro Martín, Miguel, y Fraile, 2005) determina que, si existe escasa relación entre estos parámetros, esto se debe principalmente a la irregularidad de la cuenca a la que pertenece un lago.



1.1 OBJETIVOS GENERAL Y ESPECÍFICOS

La presente investigación está orientada a la caracterización física del MzC mediante métodos de teledetección para desarrollar información científica que sirva de base para la gestión adecuada de sus valiosos recursos naturales. Así, los objetivos específicos de la misma son los siguientes:

1. Obtener un mapa temático de uso/cobertura de suelo para el MzC en base a la clasificación por pixel de imágenes satelitales que cubran la zona de estudio.
2. Explorar la viabilidad de utilizar técnicas de teledetección y/o herramientas SIG para obtener medidas geomorfológicas que puedan ayudar a distinguir entre lagos profundos y someros.
3. Analizar la posible correlación entre variables limnimétricas de lagos y lagunas en el PNC y las características morfológicas de sus alrededores.
4. Preparar un artículo científico a enviarse a una revista indexada en LATINDEX para la disseminación de los resultados principales de la presente investigación.

CAPITULO II: MATERIALES Y MÉTODOS

2.1 ÁREA DE ESTUDIO

El área de estudio corresponde a la reserva de Biosfera del MzC, la cual está localizada en la cordillera de los Andes, colindante con el valle interandino, el Océano Pacífico, y la cuenca Amazónica (Figura 1). Cuenta con una extensión de 976601 ha (ETAPA EP, 2018).

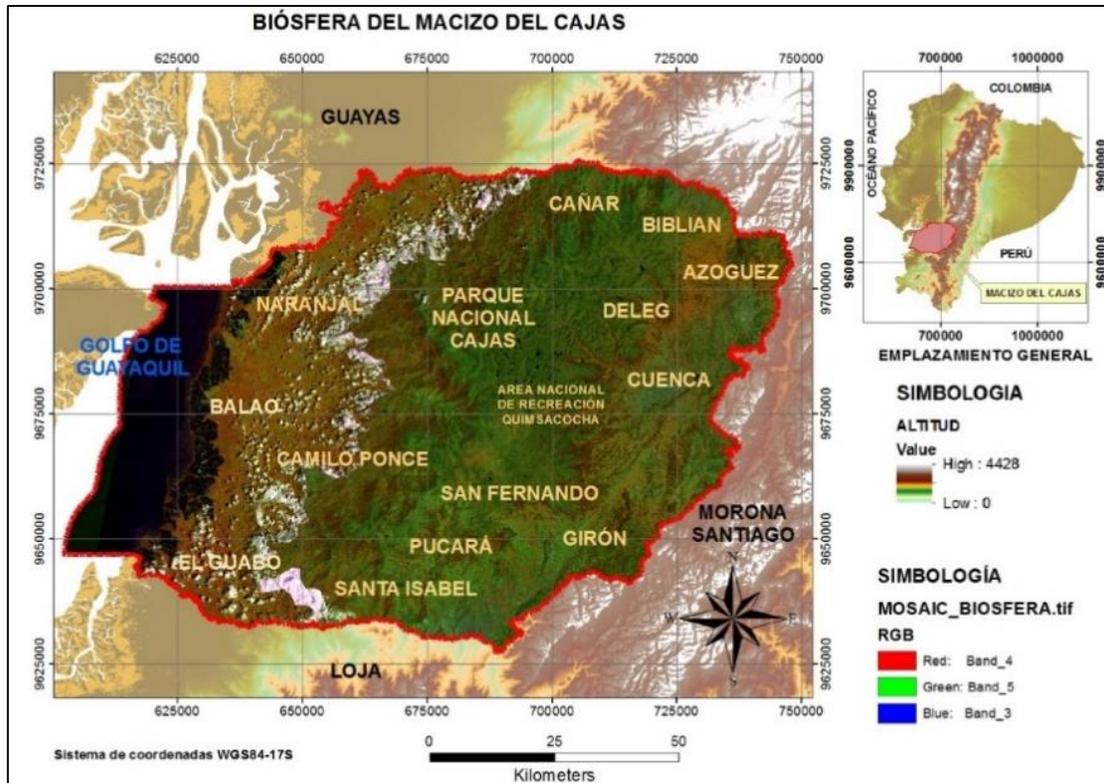


Figura 1. Área de estudio: la Biosfera del Macizo del Cajas (MzC), Ecuador.

El área está caracterizada por una variedad morfo-estructural, cuya transición de alturas va desde los 0 m s.n.m. en las cercanías del Golfo de Guayaquil, hasta alcanzar una altitud de 4500 m s.n.m., en el PNC. La principal característica de la Biosfera del MzC es la presencia del súper-páramo, donde la flora y fauna se han adaptado para poder sobrevivir a los cambios bruscos de temperatura, el viento y la radiación solar. Además, existen especies de flora únicas en el mundo, convirtiéndose en un hábitat de especies endémicas (Buytaert *et al.*, 2009).

Las características del uso de suelo son complejas como efecto de la creciente presión antrópica de los asentamientos, la variedad de la cobertura vegetal y las actividades agrícolas, ganaderas y mineras, durante los últimos 20 años. La cubierta vegetal natural está representada por pajonal, páramo, bosques interandinos y bosques de *Polylepis*. También existe alta cantidad de zonas de humedal, en sus zonas costeras existen manglares, aunque amenazados por camaroneras que en los últimos años han llegado a multiplicarse en grandes cantidades en la superficie de la biosfera (Uzcátegui *et al.*, 2016). El PNC, al ser una zona de conservación, no ha sufrido cambios importantes en su cobertura vegetal (ETAPA, 2013), lo que posibilitaría el uso de imágenes satelitales con diferentes resoluciones temporales para esta zona.



2.2 INFORMACIÓN REMOTA DISPONIBLE

Para el presente estudio se emplearon diferentes tipos de datos, entre ellos los procedentes de imágenes satelitales, ortofotos, modelos ráster temáticos, capas vectoriales, entre otros, que son detalladas a continuación.

2.2.1 Información remota disponible para el Mapa de Uso/Cobertura de Suelo

Las imágenes satelitales se obtuvieron de la página web del Servicio Geológico de los Estados Unidos (USGS) que cubrió el área de estudio con cuatro escenas del satélite Landsat 8 Operational-Land-Imager (OLI). OLI porta un sensor que provee acceso a nueve bandas espectrales en un rango de longitud de onda de 0,43 μm a los 1390 μm . Dinh (2016) presentó un estudio sobre la automatización de la clasificación de la cubierta terrestre utilizando el producto de reflectancia superficial provisional de Landsat 8 OLI, al utilizar las bandas espectrales 2 a la 7; esto para obtener un mapa de cobertura terrestre. En base a ello, el presente trabajo incluyó el análisis de las bandas espectrales de la 2 a la 7 para obtener varias composiciones de color.

Las imágenes satelitales para la zona oeste del MzC fueron tomadas el 25 de noviembre de 2016. Para la zona este, que comprende las provincias de Cañar, Azuay y El Oro, la fecha de captura fue el 6 de febrero de 2016. Las imágenes de la zona costera que incluyen el Golfo de Guayaquil fueron captadas el 19 de mayo de 2016. Un mosaico de estas imágenes multi-espectrales fue realizado para cubrir el área de la Biosfera, eliminando la nubosidad, para esto se empleó la herramienta Mosaic en el software Arc GIS 10.1.

Además, se usó información de ortofotos, información vectorial y el modelo digital de elevaciones del terreno (MDE), cuyas características principales se encuentran listadas en la **¡Error! No se encuentra el origen de la referencia.** Esta información la proporcionó la Secretaria Nacional de Planificación y Desarrollo del Ecuador (SENPLADES), Zonal 6, y la Empresa Pública Municipal de Telecomunicaciones, Agua Potable, Alcantarillado y Saneamiento de la ciudad de Cuenca (ETAPA EP.). La información de control PNC es mostrada en la Figura 2.

Tabla 1. Información digital geográfica disponible para el desarrollo del mapa del uso/cobertura del suelo en el Macizo del Cajas (MzC).

Descripción	Año	Resolución [m^2]	Fuente
Imagen Satelital Landsat 8	2015-2016	30 x 30	USGS
Ortofoto	2012	5 x 5	SIG. Tierras
MDE	2015	30 x 30	SIG. Tierras
Datos vectoriales	2016	--	ETAPA EP

Leyenda: USGS = United States Geological Survey. SIG. Tierras = Sistema Nacional de Información y Gestión de Tierras Rurales e Infraestructura Tecnológica (Ministerio de Agricultura de Ecuador).

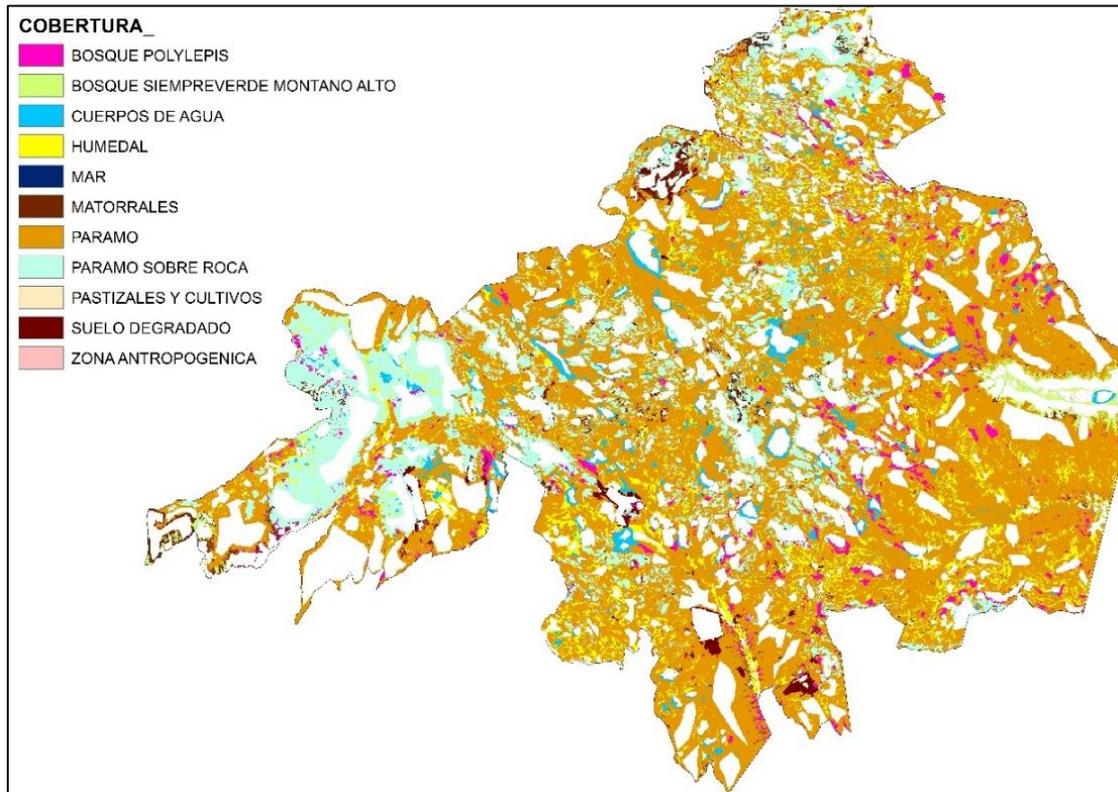


Figura 2. Información de control disponible para el Parque Nacional Cajas (PNC), Ecuador.

2.2.2 Información remota disponible para el estudio de profundidades de lagos

Como punto de partida, el presente estudio utilizó dos bandas de la región visible de la plataforma de Landsat 8; azules y rojas para el método de regresión lineal de una sola banda (SB), tomando como referencia el sistema Geodésico Mundial del año 1984 (WGS84) por sus siglas en inglés. La elección de la escena de Landsat fue en concordancia a la calidad de la misma, tratando de evitar la presencia de nubosidad en medida de lo posible (en los últimos cinco años, todas las escenas poseen un alto porcentaje de nubosidad).

Por otro lado, el estudio se limitó al análisis de 135 cuerpos de agua, para los cuales se dispone de una base de datos batimétricos a detalle y que fueron otorgados por la empresa ETAPA EP., y se muestra en el Anexo 1. Ver Figura 3.

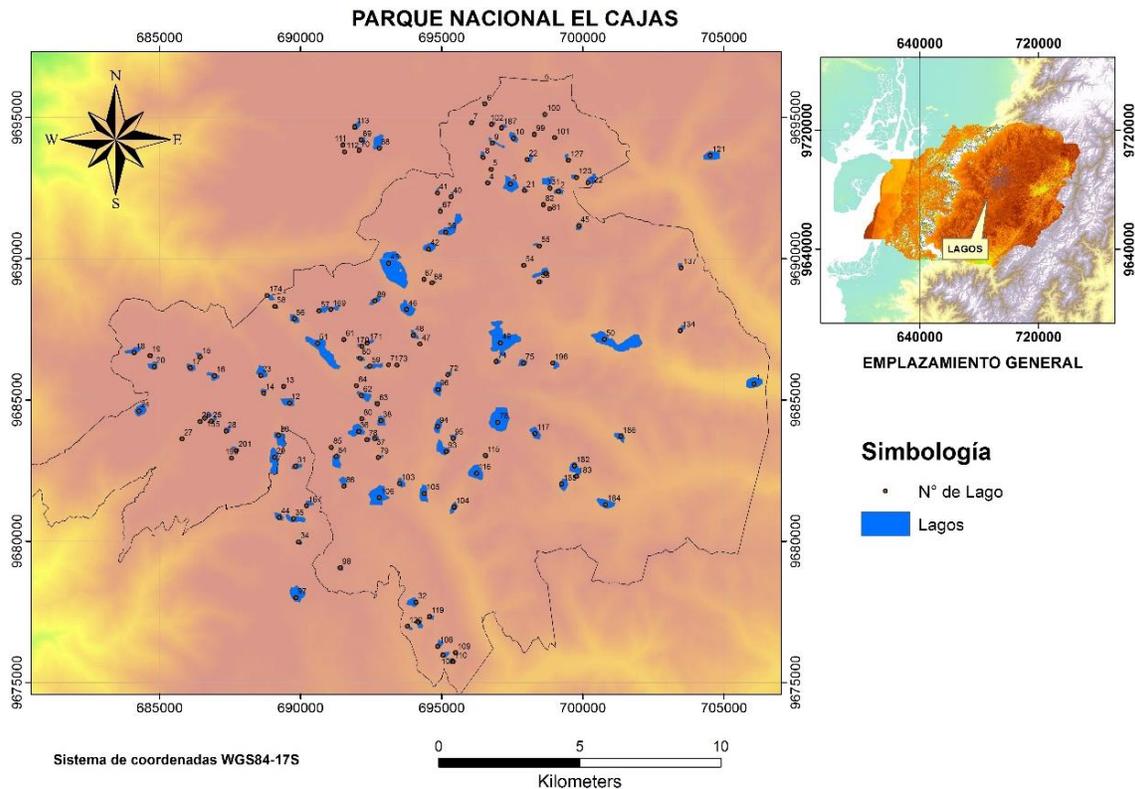


Figura 3. Mapa de control de los cuerpos de agua examinados de la biosfera del Macizo del Cajas (MzC).

Se examinó el efecto del viento sobre el área de estudio, siendo éste débil en las fechas de adquisición de las imágenes. Esto ocurre debido a que los vientos máximos se presentan durante los meses de agosto y septiembre, la estación de verano típica en lagos tropicales en los Andes (Buytaert *et al.*, 2007). De igual manera, se observaron las tablas meteorológicas de precipitaciones presentados por el Instituto Nacional de Meteorología e Hidrología (INAMHI), que tampoco exhibieron una intensidad efectiva varios días antes de la recolección. En esta misma línea se trató de obtener escenas satelitales con las fechas concordantes a la información de campo, proporcionadas por los datos de control.

Aunque las imágenes satelitales se han usado para la recuperación de la profundidad, simultáneamente se emplearon variables secundarias, recolectadas previamente para caracterizar la batimetría de campo, que describen las características físicas de los lagos de las cuencas hidrográficas adyacentes.

2.2.3 Información disponible para el análisis de correlaciones entre variables limnológicas y morfo-métricas de lagos y lagunas en el PNC.

La información de control fue proporcionada por el Laboratorio de Ecología Acuática (LEA) de la Universidad de Cuenca (UC) y ETAPA EP. Esta base de datos contiene un registro de 145 lagos, cubriendo información detallada sobre su profundidad máxima, volumen, longitud de orilla, área y pendiente de la cuenca, con amortiguadores de 50 m, 100 m, 200 m, 500 m, 1000 m, cuenca, y microcuenca. La profundidad máxima medida en el campo para estos lagos varía entre 1 m a 77 m con un campo promedio de profundidad máxima medida de 30 m. Las superficies de los cuerpos de agua son mayores a 0,01 Km² y máximas de 0,77 Km².

La mayor concentración de cuerpos de agua con áreas extensas se encuentra en la parte central del PNC, y merma drásticamente de acuerdo con la disminución de la elevación. El 80% de estos se encuentran en elevaciones entre los 3500 m s.n.m. y los 4000 m s.n.m. La distribución de la ubicación de los lagos y lagunas es heterogénea a lo largo del área de estudio. El registro está clasificado con la ubicación mediante coordenadas Universal Transversal de Mercator (UTM), con su respectiva elevación; asimismo, cada cuerpo de agua posee una denominación y numeración, ver **¡Error! No se encuentra el origen de la referencia.** El Anexo 1 detalla las 145 bservaciones, incluyendo cada una de las coordenadas y los nombres de los lagos.

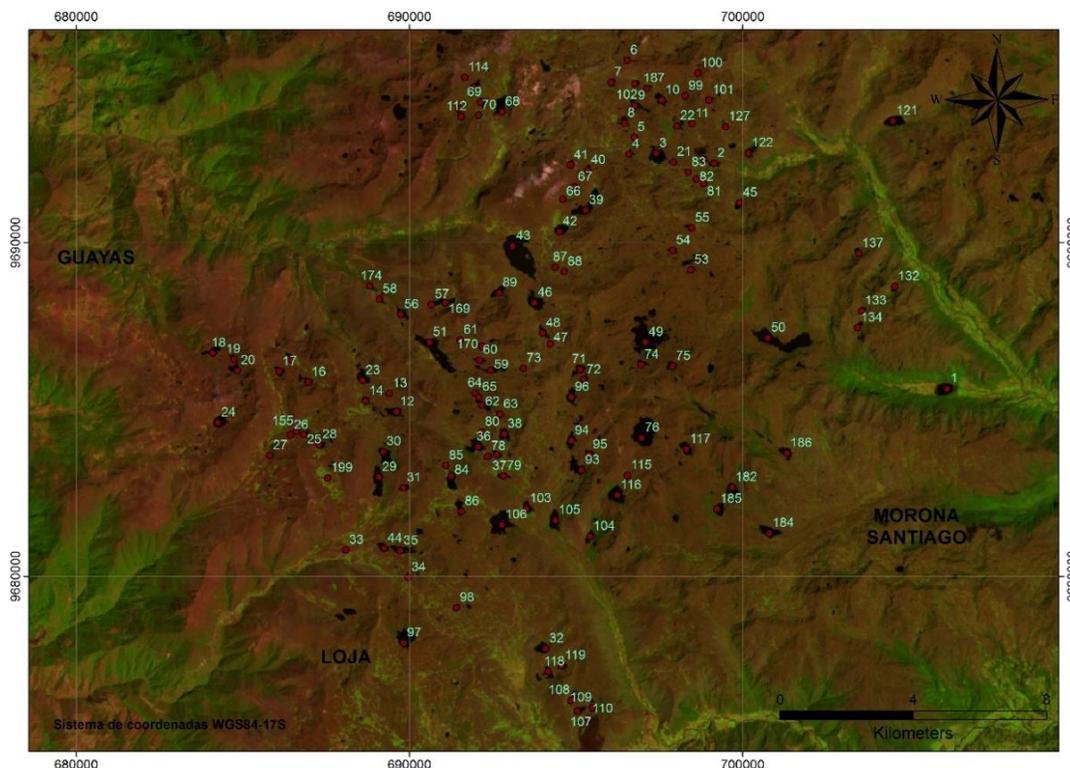


Figura 4. Distribución espacial de los 145 lagos y lagunas y de la información puntual de control proporcionada



por el Laboratorio de Ecología Acuática (LEA) de la Universidad de Cuenca (UC) y ETAPA EP.

2.3 Procesamiento previo de las Imágenes Satelitales

Chuvienco (2008) señala que las deformaciones más comunes en las imágenes satelitales son provocadas por el movimiento de la tierra, modificaciones en el sensor y variaciones provocadas por la atmósfera. Esto conlleva a que la radiancia registrada por el sensor no sea la misma que la emitida por las superficies terrestres. Todos estos errores son registrados en los píxeles de la matriz digital o matriz numérica bidimensional, por lo que, para eliminar cualquier anomalía detectada en la imagen, se requiere de algunas correcciones necesarias a fin de mejorar las imágenes tanto en la ubicación como en los valores de los ND de cada una de ellas.

A continuación, se introduce el concepto de las correcciones geométrica, radiométrica y atmosférica (Du and Sun, 2004), normalmente realizadas en el procesamiento previo de las imágenes.

2.3.1 Corrección Radiométrica

La respuesta radiométrica que llega al sensor del satélite desde la superficie se modifica a consecuencia de su paso por la atmósfera, y afecta a la radiación en su longitud de onda, intensidad, distribución espectral y/o su dirección (Meyer *et al.*, 2003). Así la información obtenida por el sensor sobre un objeto determinado puede estar afectada por varios factores de la atmósfera, incluyendo las características de respuesta del sensor.

Entre los principales efectos atmosféricos en la radiación están; la absorción y dispersión, mismos que afectan a la Trasmisividad, Radiación difusa y Radiación atmosférica. Por otra parte, las distorsiones radiométricas provocadas por el sensor se refieren a errores sistemáticos en las bandas de las imágenes, que pueden ser corregidas calibrando los parámetros físicos a partir de los ND de la imagen. (Liang *et al.*, 2001)

El proceso de corrección trata los valores de un píxel de la imagen satelital para obtener valores de intensidad homogéneos, equilibrando histogramas o corrigiendo imperfecciones presentes en los píxeles. Según Rejas Ayuga (2008), las correcciones radiométricas más comunes se refieren a: (i) corrección radiométrica del bandeo, en sensores de barrido producido por desajustes en el calibrado de los detectores; (ii) corrección radiométrica de líneas o píxeles perdidos, producido por fallos del sensor o de transmisión de los datos; (iii) corrección o normalización radiométrica horaria; (iv) corrección radiométrica del efecto por columnas; y (v) correcciones atmosféricas.



2.3.1.1 Corrección Atmosférica

Para Gandía Franco and Meliá Miralles (1991), la aplicación de la corrección atmosférica en imágenes satelitales usualmente se emplea en estudios en los cuales intervienen diferentes bandas de una imagen multi-espectral, para estudios multi-temporales, interpretación de diferencias de magnitudes relacionadas al estrés de la vegetación y concentración de clorofila, entre otros. En este contexto, la presente investigación recae en el análisis multi-temporal de imágenes satelitales, por lo tanto, se define como tratamiento previo de las mismas a la corrección atmosférica.

Para el caso de estudios multi-temporales, la corrección puede abordarse como una conversión de los ND en valores de radiancia, la cual corresponde a la cantidad de energía electromagnética que pasa a través del sensor o es emitida desde un área en particular y llega al sensor. El cálculo o estimación de la radiación que llega a un sensor, está basado en la radiación procedente del suelo multiplicada por la transmisividad de la atmósfera en camino ascendente, más la radiancia aportada por la dispersión atmosférica. (Riaño *et al.*, 2000)

En el presente trabajo se empleó el modulo avanzado de corrección atmosférica disponible en el software QGIS (Quantum Development Team), el cual se basa en el algoritmo de transferencia de radiación MODTRAN4 desarrollado por Spectral Sciences Inc. La corrección atmosférica estima la radiancia propia del objeto en la superficie, proporcionada por la señal recibida por el sensor y se calcula mediante tres pasos: (1) convertir los ND de cada banda a valores de radiancia (L); (2) la radiancia se transforma a valores de reflectividad en el techo de la atmósfera “Top of Atmosphere” (TOA); y (3) se convierte la reflectividad a valores de reflectancia (Kruse, 2004) mediante el módulo FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) disponible en el paquete software ENVI 5.1 (Environment for Visualizing Images). En SIGMUR (2006) se describe de manera completa el modelo matemático sobre el cual se basa esta corrección.

2.3.1.1.1 Conversión de los niveles digitales (ND) a valores de radiancia

La Radiancia es la cantidad de energía electromagnética que pasa a través o es emitida desde un área en particular, y que puede calcularse a través de los coeficientes de calibración del sensor, mediante:

$$L_{sen, k} = a_{0,k} + a_{1,k} \cdot ND_k \quad (1)$$



, donde: $L_{sen,k}$ es la radiancia espectral recibida por el sensor en la banda k en [Watts m^{-2} _srad μm]; $a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración para esa banda; y ND_k es el nivel digital de la imagen en la misma banda.

Por otro lado, la radiancia que llega al sensor es una función de la irradiación solar; es decir, por un lado reducida por la absorción atmosférica y, por otro, incrementada por la radiancia introducida por la propia atmósfera (dispersión). La reflectividad de la cubierta y las condiciones de adquisición (tipo de sensor, la altitud del sensor con respecto al nivel del mar, la fecha y la hora de la captura), son:

$$L_{sen,k} = (E_{0,k} \cos \theta_i \rho_k^*) / (K\pi) \quad (2)$$

, donde: $L_{sen,k}$ es la irradiancia solar en el techo de la atmosfera (TOA), $E_{0,k}$ es la irradiancia solar en el techo de la atmosfera en la banda k [$W m^{-2} \mu m^{-1}$], ρ_k^* es la reflectividad aparente de la cubierta en la banda k , θ_i es el ángulo cenital del flujo incidente (formado por la vertical y los rayos solares), y K es el factor corrector de la distancia Tierra-Sol, que se calcula como:

$$K = (1 + 0.0167(\sin(2\pi(D-93.5)/365)))^2 \quad (3)$$

, donde, D es el día en el calendario juliano y el seno se calcula en radianes.

2.3.1.1.2 Conversión a valores de Reflectividad

Un segundo paso para la corrección de las imágenes satelitales es la estimación de los valores de reflectividad aparente, conociendo la irradiación solar y la fecha de adquisición de la imagen. Despejando en (2) la reflectividad aparente, obtenemos la siguiente fórmula (%):

$$\rho_k^* = \frac{(K \pi L_{sen,k})}{(E_{0,k} \cos \theta_i)} \quad (4)$$

Después, los ND de las imágenes se corrigieron, transformando los valores originales de radiancia del terreno a reflectancia superficial. Los valores finales varían en el rango que va de 0 a 1. La **¡Error! No se encuentra el rigen de la referencia.** muestra el resultado de la corrección atmosférica realizada con este pre-procesamiento.

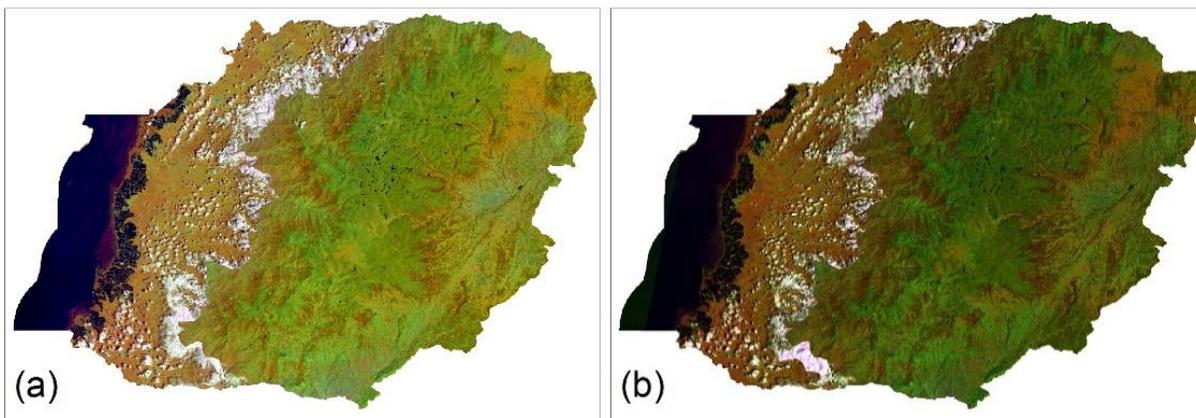


Figura 5. Capturas de pantalla que muestra las bandas 2,5 y 6 de Landsat 8 OLI: (a) antes de la corrección atmosférica; y (b) luego de la corrección atmosférica.

Las bandas espectrales del sensor LANDSAT 8, que se emplearon para la composición, fueron de la 2 a la 7, de tal forma que se pudieron obtener varias composiciones de color, facilitando la visualización e interpretación de algunas coberturas, lo que también posibilitó la elección de opciones de procesamiento.

2.4 Generación del mapa de Uso/Cobertura del suelo para el MzC

Después del pre-procesamiento de las imágenes, se creó un conjunto de 300 polígonos de entrenamiento (ROIs) por cada clase de uso de suelo. El tamaño de los ROIs varió entre uno y diez hectáreas. En la Tabla 2 se muestran las categorías de cobertura vegetal que se consideraron en el estudio.

Tabla 2. Información digital geográfica disponible para el mapa de uso de suelo.

Clase	Descripción	Clase	Descripción
1	Bosque Polylepis (BP)	14	Suelo Degradado (SD)
2	Bosque Siempreverde (BV)	15	Zona Antrópica (ZA)
4	Cuerpos de Agua (CA)	3	Camaronera (CAM)
5	Humedal (HM)	6	Manglar (MG)
8	Matorrales (MT)	7	Mar (MR)
10	Páramo Pajonal (PA)	9	Nubes (NU)
11	Páramo sobre Roca (PR)	13	Sombras (SO)
12	Pastizales y Cultivos (PZ)		



Las clases de uso/cobertura de suelo incluyen, los Pastizales y Cultivos (PZ) engloban las áreas destinadas a la agricultura, cultivos, pastoreo y ganadería. El Páramo Pajonal (PA) está caracterizado por pajonales generalmente altos y con pocas plantas herbáceas no gramíneas, sin estrato arbustivo. El Páramo sobre roca (PR) está en las cimas de los picos más altos con especies como *Nototriche hartwegii* y *Valeriana henricii* (Josse *et al.*, 2003).

El Bosque Polylepis (BP) indica vegetación endémica de los Andes (Kessler, 2006). El Bosque Siempreverde (BV) se caracteriza por vegetación de transición entre el bosque montano y el páramo. La cobertura Matorrales (MT) hace referencia a las formaciones vegetales de los bosques secos con plantas espinosas y tonalidades grises y cafés (Sierra, 1999). El Suelo Degradado (SD) se refiere a las áreas en las cuales la erosión es evidente y lugares en donde ocurrieron incendios forestales. La Zona Antrópica (ZA) está constituida por los asentamientos humanos, ciudades, vías de comunicación y fábricas.

Las imágenes satelitales usadas para el estudio presentaron una gran cantidad de nubosidad, en una zona de transición entre la costa y la sierra, por lo que se optó por adicionar la categoría Nubes (NU) para evitar confusiones durante el proceso de clasificación de las imágenes. La categoría Sombras (SO) es causada por estas nubes.

El área del Océano Pacífico se clasificó como Mar (MR). La clase cuerpos de Agua (CA) incluye a los lagos, lagunas, ríos y lagunas de estabilización. Las Camaroneras (CAM) se encuentran en la costa del Ecuador y tienen una resolución espectral distinta a la de los cuerpos de agua. El Manglar (MG) es la zona plana de los estuarios colindantes al mar. La clase Humedal (HM) corresponde a los arroyos permanentes, lagos estacionales intermitentes de agua dulce, arroyos estacionales, pantanos esteros, charcas permanentes e intermitentes de agua dulce (Secretaría de la Convención de Ramsar, 2013).

Los 300 polígonos de entrenamiento creados por cada clase de uso de suelo, se basaron en la información adicional de ortofotos con resolución de 5x5 m² y los MDE como se observa en la **¡Error! No se encuentra el rigen de la referencia..** El tamaño de los polígonos de entrenamiento, tienen áreas mayores a 1 ha y menores a 10 ha.

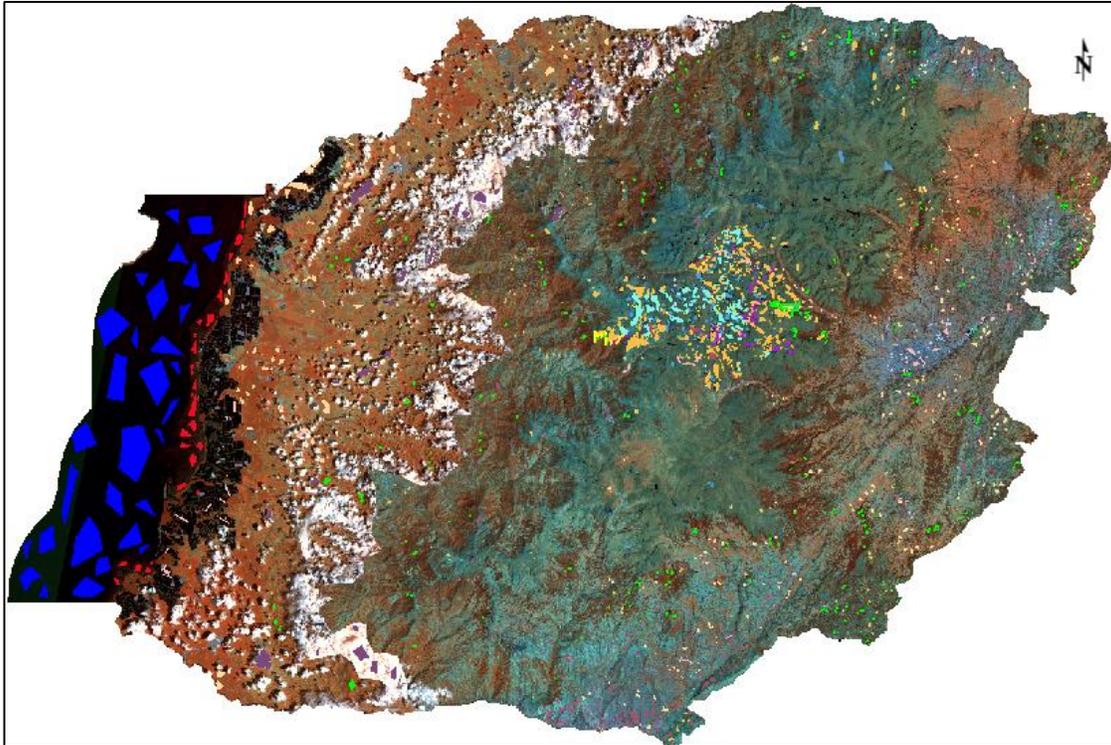


Figura 6. Polígonos de entrenamiento para cada clase de uso/cobertura de suelo en la Biosfera del Macizo del Cajas

Las clases de cobertura del suelo se identificaron en base a la respuesta espectral de la imagen. Así, las diferencias espectrales entre pares de clases de cobertura de suelo fueron evaluadas con la herramienta ROI Separability del Software ENVI 5.3. Luego, se emplearon los métodos de clasificación supervisada de las imágenes satelitales: MV, MH y ANN. En términos generales, el rendimiento de cualquiera de estos métodos depende de la consistencia, homogeneidad y separabilidad de las clases y de lo representativas que estas puedan ser.

2.4.1 Método de Máxima Verosimilitud (MV)

En el método MV una función de distribución normal describe a cada categoría a partir de un vector de medias y una matriz de varianza-covarianza. Aunque demanda mucho esfuerzo computacional, este clasificador es muy utilizado en teledetección por sus altas prestaciones al momento de ajustarse a la información del territorio. Richards and Jia (2006) exponen de forma más rigurosa el funcionamiento de este método.

El clasificador MV asume que los datos siguen una función de distribución normal para asignarle una probabilidad a que un pixel cualquiera pertenezca a cada una de las clases. De este modo, el pixel es asignado a la clase a la que es más probable que pertenezca. Además, al contar con la media y la desviación típica de cada una



de las clases, es usada una distribución de probabilidad. Este método puede establecer algún criterio que permita asignar pixeles a una clase sólo si su probabilidad es superior al umbral impuesto. Por otro lado, este define el criterio para medir la calidad de la asignación, por decir con la diferencia entre la máxima probabilidad y la siguiente.

El clasificador de máxima probabilidad se basa en la clasificación de Bayes, donde las clases espectrales se representan así (Hogland *et al.*, 2013): C_i donde $i = 1 \dots N$ y N representa el número de clases por determinar la clase de un píxel particular con el vector de medición \mathbf{v} , las probabilidades condicionales son las siguientes:

$$P(C_i|V), i=1 \dots N \tag{5}$$

Si hay un conjunto completo de probabilidades de condición $P(C_i|V)$ para un píxel, podríamos etiquetar el píxel de acuerdo con la regla de decisión:

$$\mathbf{v} \in C_i \text{ si } P(C_i|V) > P(C_j|V) \text{ para todos } j \neq i \tag{6}$$

(6) representa, el píxel con el vector de medición \mathbf{v} es un miembro de la clase C_j , si $P(C_j|V)$ es la mayor probabilidad del conjunto. Establecemos el conjunto de probabilidad condicional de la clase $P(V|C_i)$, que se describe como las posibilidades de encontrar un píxel en la posición V en cada una de las clases C_j .

$P(V|C_i)$, es la función de probabilidad condicional que se estima a partir de los datos de entrenamiento etiquetados para cada clase. El $P(V|C_i)$ deseado y el $P(V|C_i)$ disponible se estiman a partir de los datos de entrenamiento y las reglas del teorema de Bayes:

$$P(C_i|V) = \frac{P(V|C_i)P(C_i)}{P(V)} \tag{7}$$

, donde, $P(C_j)$ es la probabilidad de que el píxel de la clase C_j aparezca en cualquier lugar del mapa y $P(V)$ es la probabilidad de encontrar un píxel con vector V de medición en el mapa $P(V)$ anotado como:

$$P(V) = \sum_{i=1}^N P(V|C_i)P(C_i) \tag{8}$$

Sustituyendo (7) en (8), se obtiene:

$$\mathbf{V} \in C_i \text{ si } P(V|C_i) P(C_i) > P(V|C_j)P(C_j) \text{ para todos } j \neq i \tag{9}$$



, la cual es más aceptable porque $P(V|C_i)$ es conocida a partir de los datos de entrenamiento. Además, el clasificador de máxima probabilidad requiere un modelo de probabilidad para la clase de función condicional $P(V|C_i)$. Así que se asume $P(V|C_i)$ como una distribución normal multivariable que también se conoce como una distribución gaussiana.

Para un N espacio tridimensional, la función de distribución gaussiana multivariable es:

$$P(V|C_i) = (2\pi)^{-\frac{N}{2}} |Y_i|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (V-Z_i)^T Y_i^{-1} (V-Z_i) \right\} \quad (10)$$

, donde, Z_i es el vector medio e Y_i la matriz de covarianza de los datos en la clase C_j .

2.4.2 Método de la distancia de Mahalanobis (MH)

La distancia Euclidiana no es acotada, es sensible a cambio de escalas y considera a las variables como estocásticas e independientes. Una variante es la distancia de Mahalanobis (Mahalanobis, 1936), que considera las correlaciones entre variables, la redundancia que existe entre las mismas y las medias y varianzas de todas las variables. Por ende, tiene en cuenta la variabilidad de las clases. Este método tiende a clasificar en exceso las firmas espectrales con valores relativamente grandes en la matriz de covarianza y se basa en gran medida en una distribución normal de los datos en cada banda de entrada (Willington *et al.*, 2013).

La expresión matricial de la distancia está dada por:

$$d_m(\vec{x}_1 - \vec{x}_2) = \sqrt{(\vec{x}_1 - \vec{x}_2)^T \Sigma^{-1} (\vec{x}_1 - \vec{x}_2)} \quad (11)$$

, donde, Σ es la matriz de varianzas-covarianzas entre las n variables (rasgos funcionales), x_1, x_2 es el valor de cada pixel en la banda n para cada fila y columna, d_m es la distancia Mahalanobis. Si las n variables son independientes, la sumatoria será diagonal y la distancia de Mahalanobis se aproximará a la distancia Euclidiana al cuadrado con pesos inversos dados por las varianzas de las n variables.

2.4.3 Método de Redes Neuronales Artificiales (ANN)

Las redes neuronales son algoritmos de procesamiento que permiten reconocer patrones en los datos, a partir de modelos que simulan los sistemas biológicos de aprendizaje. De manera general, una red neuronal está compuesta



por unidades de procesamiento llamadas neuronas, distribuidas en diferentes capas, conectadas entre sí por una serie de pesos que establecen las relaciones entre ellas (Dong *et al.*, 2009).

En una neurona se realizan tres tipos de operaciones para determinar su funcionamiento. La primera operación es la regla de propagación que integra la información proveniente de las distintas neuronas artificiales y proporciona el valor del potencial pos sináptico de la neurona i , la función de activación provee el estado de activación actual de la neurona y la función de salida representa la salida actual de la neurona (Freeman and García-Bermejo, 1993).

El peso sináptico W_{ij} define la fuerza de una conexión entre dos neuronas. Mediante el ajuste de estos, la red es capaz de adaptarse a cualquier entorno y realizar una determinada tarea (Kavzoglu and Mather, 2003). Partiendo de un conjunto de pesos sinápticos aleatorios, el proceso de aprendizaje busca un conjunto que permitan a la red desarrollar correctamente una determinada tarea (Silvan-Cardenas, 2004).

El proceso de entrenamiento empleado en este estudio fue el algoritmo de retro-propagación. Este es un procedimiento iterativo de entrenamiento de descenso de gradiente, el cual es un caso simple de clasificación. La información de entrada fueron los vectores multi-espectrales de los pixeles de entrenamiento, una banda por nodo. En cada nodo de la capa media se produjo una sumatoria y una transformación, para cada nodo j de la capa media llega una entrada p_j , ponderada sobre la cual se efectuaron las siguientes operaciones (Yuan *et al.*, 2009):

$$\text{net}_j^p(t) = \sum_{i=1}^N w_{ij} * x_i^p(t) + \theta_j \quad (12)$$

, donde, θ_j es el umbral de la neurona que se considera como un peso asociado a una neurona ficticia con valor de salida igual a 1. El valor de salida de la neurona oculta j , se obtiene aplicando la función de activación f sobre su entrada neta:

$$y_j^p(t) = f(\text{net}_j^p(t)) \quad (13)$$

De igual forma, la entrada neta que recibe una neurona de salida k , es:

$$\text{net}_k^p(t) = \sum_{j=1}^H w_{kj} * y_j^p(t) + \theta_k \quad (14)$$



Por último, el valor de salida de la neurona de salida k , es:

$$y_k^p(t) = f(\text{net}_k^p(t)) \quad (15)$$

La salida de la red de cada neurona y_k^p se compara con la salida deseada d_k para calcular el error en cada unidad de salida. El objetivo fue hacer mínimo el error entre la salida obtenida por la red (las bandas pertenecientes a las imágenes satelitales) y la salida deseada por el usuario (las 15 clases deseadas) ante la presentación de un conjunto de patrones p denominado grupo de entrenamiento. La función de error que se minimizó para cada patrón p fue dada por:

$$\text{RMS}^p = \frac{1}{2} \sum_{k=1}^M (d_k - y_k^p)^2 \quad (16)$$

Este proceso se repitió para el número total de patrones de entrenamiento P (polígonos de entrenamiento) (Bertona, 2005). Para un proceso de aprendizaje exitoso el algoritmo se actualizó con todos los pesos y ganancias de la red minimizando el error medio cuadrático total descrito como:

$$\text{RMS} = \sum_{p=1}^P E^p \quad (17)$$

La base del algoritmo de retro-propagación para la modificación de los pesos es la técnica conocida como gradiente decreciente que es:

$$W(t+1) = W(t) - \alpha \nabla E[W(t)] \quad (18)$$

, donde, α es el tamaño del paso o tasa de aprendizaje, que suele ser una constante de tamaño reducido, con $0 < \alpha < 1$.

2.4.4 Evaluación de los productos de los métodos de clasificación

Para la evaluación de la calidad de los productos de los métodos de clasificación se contó con la información de control del PNC, entregada por ETAPA EP. Esta contiene la cobertura del uso del suelo digitalizada a partir de fotografía aérea y filtrada con una validación en campo y el asesoramiento de expertos conocedores del medio físico.



La información contiene 25 categorías de uso del suelo y cobertura vegetal. Por lo tanto, para poder realizar la evaluación de la calidad de los mapas obtenidos por los diferentes métodos antes señalados, se redujo este sistema de clasificación de acuerdo a las 15 clases de la Tabla 2. El proceso de reducción fue necesario para áreas inferiores a 0,1 ha cuya información “se pierde” en la resolución original de Landsat por las características espectrales similares. Por ejemplo, existen en la cartografía digitalizada de ETAPA EP coberturas tales como matorrales *Oerocalis Grandiflora* y matorrales *Luiotike*, que se agruparon en una sola cobertura denominada “MT”.

La calidad de los productos de los métodos de clasificación fue evaluado utilizando el error relativo absoluto (ERA) que se calcula dividiendo el valor absoluto de la diferencia entre el producto del método de clasificación y la información de control (valores observados) para la media de la información de control.

$$ERA = \frac{\text{Abs(Inf. Control - Inf. obtenida por ANN ó MV ó MH)}}{\text{Inf. Control}} \quad (19)$$

De esta forma, un valor pequeño de este índice adimensional indica un mejor producto del proceso de clasificación de las imágenes espectrales ya que el numerador de la división se aproximaría a cero.

Esta evaluación se llevó a cabo en modo ráster, a una resolución de $5 \times 5 \text{ m}^2$ para no perder demasiado el detalle espacial de información (vectorial) original de ETAPA EP. En vista de que tanto las imágenes Landsat como los respectivos productos de aplicar los métodos de clasificación sobre las mismas tienen una resolución de $30 \times 30 \text{ m}^2$, fue necesario transformar (Vázquez y Feyen, 2007) esta resolución a $5 \times 5 \text{ m}^2$ con una división simple de cada pixel original de $30 \times 30 \text{ m}^2$ en 36 pixeles de $5 \times 5 \text{ m}^2$, conteniendo todos la misma información que la del pixel original.

Aunque este procedimiento de transformación de una resolución gruesa a una más fina implica un error importante en relación a la condición real del territorio, se cree que es bastante inferior a la pérdida de información que se cometería al pasar la capa vectorial de ETAPA EP a la resolución de $30 \times 30 \text{ m}^2$ para llevar a cabo el control de calidad de la clasificación de imágenes.



El análisis se efectuó con los paquetes informáticos de SIG ARCMAP® 10.1 y TerrSet. El álgebra de mapas (raster) entre los productos de los métodos de clasificación y la información de control se efectuaron para cada clase de cobertura, considerando los ROIs reservados para la validación de los métodos, es decir, sin emplear los ROIs utilizados durante el proceso de clasificación.

Después de seleccionar el mejor método de clasificación de imágenes, se aplicaron dos filtros sobre el producto correspondiente. El objetivo de este análisis fue reducir de la mejor forma posible el ruido presente en el producto obtenido por el método seleccionado. El primer filtro fue el Majority Filter (MF) que elimina el efecto denominado “sal y pimienta”. El segundo filtro aplicado fue la combinación de los procesos denominados Sieve Classes (SC) y Clump Classes (CC) que permiten el suavizado y eliminación de polígonos islas del producto del método de clasificación. Este análisis se lo efectuó con la ayuda del paquete informático ENVI 5.3. De la misma forma que para los métodos de clasificación, la calidad de los productos de estos filtros fueron evaluados con el estadístico ERA.

2.5 Estimación de las profundidades de lagos y lagunas en el PNC

Como se mencionó, la información procedente de los lagos fueron procesados utilizando el software ENVI 5.3, para la corrección por reflectancia para las bandas azul y roja. Posteriormente se realizó un enmascaramiento de los lagos a ser evaluados, así se separó el agua del terreno circundante para determinar la zona limnética. Para tal fin se empleó el mapa de uso/cobertura de suelo obtenido con el software ArcMap 10.1, y con la finalidad de trabajar con la menor cantidad de datos de tal modo que el procesamiento sea ágil y rápido (Figura 7).

En Van Colen *et al.*, (2017) se muestra que estos lagos poseen una transparencia de agua baja, debido a las altas concentraciones de carbono orgánico disuelto y esto por el desarrollo de la cuenca en pastizales, roca desnuda y paramos, de ahí que la radiación UV-B es absorbida en los 0,5 m superiores de la columna de agua.

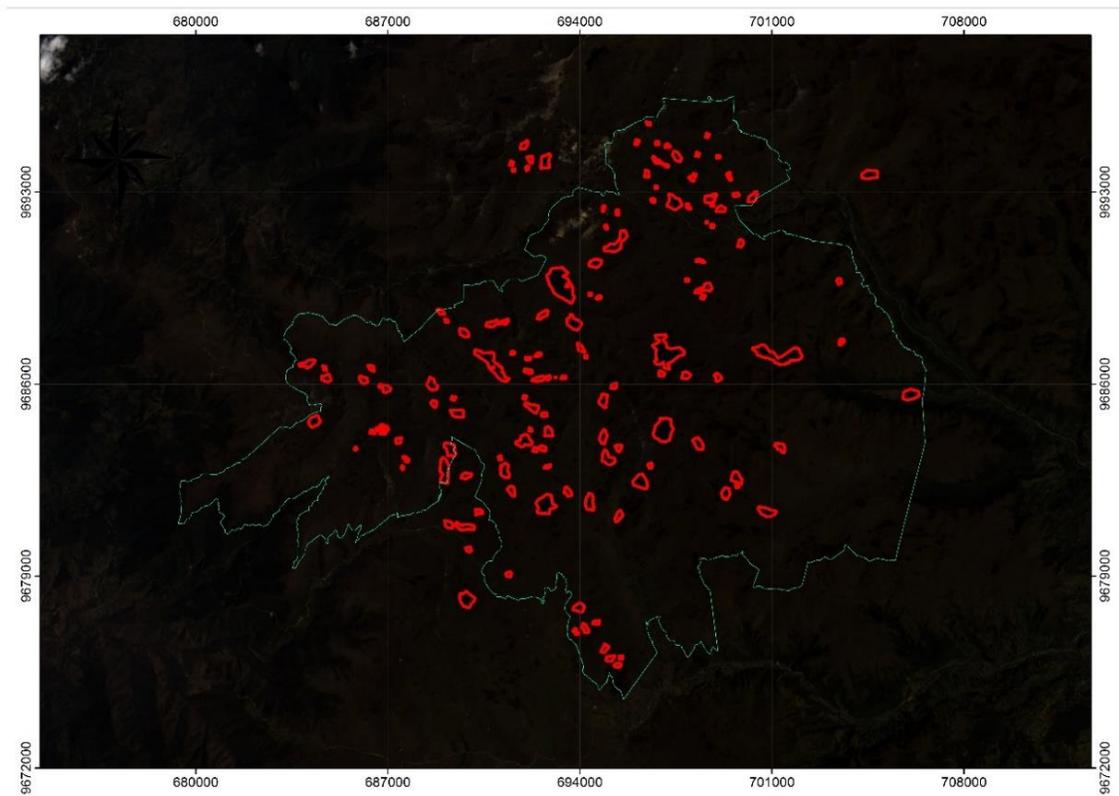
La extracción de los valores de los píxeles se realizó sobre las escenas de imágenes Landsat 8, corregidas por radiancia y reflectancia. El valor del píxel de la imagen derivada del satélite se obtiene con la referencia del valor del punto de profundidad media procedente de la base de datos disponible. Al aumentar la profundidad, la luz que penetra en el agua disminuye (atenuación), lo cual varía con la longitud de onda de la radiación electromagnética. Generalmente las señales de detección remota son dependientes del fondo marino y de la profundidad, para la corrección de la atenuación se sigue el modelo propuesto por Lyzenga (1981).

El proceso de atenuación que sufre un rayo de luz al atravesar una columna de agua, se debe tanto a la absorción (coeficiente de absorción, α_a) como a la dispersión (coeficiente de dispersión, α_s), y representa la fracción de la energía que pierde un haz de luz cuando avanza una longitud de unidad a través del agua (Jagalingam *et al.*, 2015).

La reflectancia del interior de una masa de agua se define como la fracción de energía reflejada desde el interior de la masa acuática, esto es, el cociente entre la irradiancia ascendente, y la descendente, medidas ambas justo bajo la superficie del agua. El coeficiente de extinción (k) describe la razón a la cual la energía es atenuada conforme la profundidad aumenta, de acuerdo a la siguiente ecuación (Lyzenga, 1985):

$$E_z = E_0 e^{-2kz} \quad (20)$$

, donde, E_0 es el valor de la reflectancia en la superficie y E_z es el valor de la reflectancia a una profundidad z .



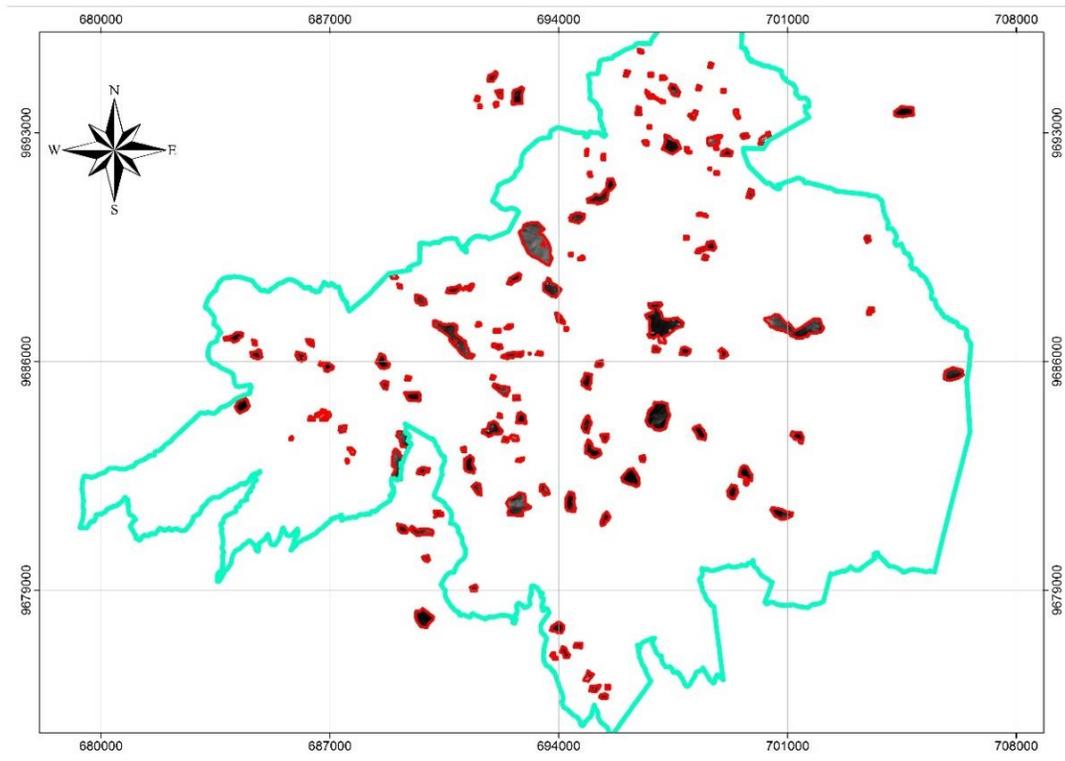


Figura 7. Ilustración del enmascaramiento de los lagos y lagunas. Se empleó la información únicamente dentro del contorno de los lagos.

En el rango visible y en la región espectral del infrarrojo cercano (NIR), el agua pura absorbe totalmente la radiación dependiendo de la longitud de onda concreta. Así, la radiación en un entorno de 0,5 micras puede llegar hasta varias decenas de metros. La radiación del infrarrojo medio sólo penetra unos milímetros. Al igual que sucede con la atmósfera, la radiación de longitud de onda inferior a 0,5 micras se ve afectada por la dispersión de Rayleigh. La profundidad a la que penetra la radiación (L) depende del coeficiente de absorción (α_a), siendo:

$$L = \frac{1}{\alpha_a} \quad (21)$$

, donde, α_a viene dado en m^{-1} y L en m.

El agua pura, en el infrarrojo térmico tiene una emisividad de aproximadamente 0,985 en $8 \mu m$ de longitud de onda, subiendo hasta aproximadamente 1 en $12 \mu m$ y descendiendo bruscamente hasta 0,96 en $14 \mu m$ (Ormeño, 2006).



Las microondas proporcionan cierta capacidad de penetración, siempre que el ángulo de incidencia sea bajo y se trabaje con longitudes de onda largas. El agua suele reflejar el pulso recibido, por lo que el retorno es bastante bajo. En caso de existir cierta rugosidad superficial, como por ejemplo oleaje, ésta puede manifestarse en la imagen obtenida por el sensor, siempre que el ángulo de incidencia sea bajo (Stumpf and Holderied, 2003).

Para la interpretación de las longitudes de onda captadas por los sensores es necesario un algoritmo que relacione matemáticamente las observaciones del satélite desde el espacio con las magnitudes que se desean estimar. Esta información se la puede obtener por métodos estadísticos (estudios de regresión). Este estudio utilizó el método de (Lyzenga, 1985) para estimar la profundidad mediante su algoritmo de SB en regresión lineal contra las profundidades conocidas.

Este método requiere menor cantidad de información espectral y auxiliar. Además, está planteado para cuando las reflectancias inferiores y el coeficiente de atenuación sean por lo general uniformes. De ahí que los cuerpos de agua no mantienen una relación directa con la profundidad debido al efecto exponencial del coeficiente de atenuación del agua, sin embargo, utilizando una transformación logarítmica de los valores de reflectancia es posible crear una nueva variable para cada banda que sí está linealmente relacionada con la profundidad. La ecuación utilizada para la estimación de la profundidad fue:

$$Z = -\frac{1}{2k_a} \ln(V - V_s) + \frac{1}{2k_a} (\ln V_0) \quad (22)$$

, donde, Z es la profundidad estimada [m], V es la radiancia observada [μm], V_s es la porción de señal resultante de la dispersión de radiación en la atmósfera [μm], columna de agua y superficie del agua [m], el coeficiente de atenuación es k_a , el factor de sensibilidad V_0 está conformado por contribuciones de la irradiación solar en la superficie, la reflectancia del fondo, la transmisión atmosférica y el equipo sensor (tipo de sensor, características propias del fabricante). De ahí que, la radiancia reflejada en el fondo es aproximadamente una función lineal de la reflectancia en el fondo y una función exponencial de la profundidad del agua (Lyzenga, 1981). Esta suposición permite derivar la siguiente ecuación:

$$V_i = \ln(V - V_s) \quad (23)$$

, donde, V_i es la radiancia ajustada por profundidad para la banda i, V es la radiancia detectada por el sensor en la banda i, V_s es la radiancia correspondiente a sitios de agua profunda. Esta linealización resalta los efectos del fondo. Suponiendo que V es constante y contando con los datos de profundidad conocida, se puede calcular los



coeficientes de atenuación por profundidad $-\frac{1}{2k_a}$ como pendiente de la ecuación, y el efecto del fondo como la constante $\frac{1}{2k_a} \ln(V_o)$.

Luego, para estimar todos los valores de (22), se partió de un análisis de regresión lineal entre profundidades conocidas y valores de radiancia transformados para una muestra de pixeles. El valor de V_s fue calculado con base en las propiedades espectrales de la imagen satelital, asumiendo que las profundidades de los lagos son mayores a 30 m y que a tal profundidad los valores de radiancia deberían ser virtualmente cero en la banda azul, y cualquier reflectancia registrada se debería sólo a la dispersión (Gholamalifard *et al.*, 2013).

De la base de datos, se observa que existen 17 lagos y lagunas con profundidades conocidas mayores a los 30 m, de esta muestra se determinó el valor promedio y se restó una desviación estándar. Para determinar los valores de radiancia transformados, se tomaron las radiancias de las bandas azul y roja de la escena satelital, se restó el valor de V_s y se calculó el logaritmo natural. Por último, se estimó la profundidad combinado la información de las dos bandas (azul y roja) a través de la siguiente ecuación (Corona Hinojosa *et al.*, 1994):

$$Z = \frac{1}{3} \sum_{i=n}^i \frac{\ln(\ln(V-V_s)) - \ln(\frac{1}{2k_a} \ln(V_o))}{-\frac{1}{2k_a}} \quad (24)$$

2.5.1 Evaluación del desempeño del algoritmo para la estima de la profundidad de los lagos del PNC

Para la evaluación del desempeño de los resultados del algoritmo para la estima de la profundidad de los lagos del PNC, como primer paso se realizó un análisis estadístico de la regresión lineal entre las profundidades conocidas y los valores de las bandas transformadas, se determinó el ajuste del modelo empleando el coeficiente de determinación, se empleó el método del análisis de la varianza (Montgomery, 2011), para probar la significancia del modelo, primero determinando la significancia global del modelo a través de la prueba de Fisher (F), y luego la significancia individual del modelo mediante la prueba t-student (T).

Por otra parte, como segundo paso para el análisis de la eficiencia del modelo, se procedió a categorizar los lagos y lagunas en tres grupos bien determinados; (a) lagos buenos: es decir aquellos para los que el correspondiente error de precisión entre las profundidades simuladas y las profundidades conocidas no superan los 5 m; (b) lagos no muy buenos: aquellos para los que el error de precisión se encuentra contenido en el rango 5-10 m; y (c) lagos malos: aquellos para los que el error supera los 10 m. Para dicha clasificación se empleó el histograma



de frecuencias para determinar la distribución y el grado de dispersión de las profundidades simuladas, tomando como base el valor absoluto de la diferencia de las profundidades simuladas y observadas.

2.6 Análisis de la posible correlación entre variables limnimétricas de lagos y lagunas en el PNC y las características morfológicas de sus alrededores

Para el análisis de la posible correlación entre variables se optó por emplear el modelo estadístico multivariado denominado Análisis de Componentes Principales (ACP), debido a la extensión de la base de datos, correspondiente a 145 entre lagos y lagunas. Esta base de datos está compuesta de variables limnimétricas que se enumeran en la **Tabla 3**, y características morfológicas de los alrededores de los lagos como: Aspectos/Orientación, Elevación y Pendiente, cada una estas características poseen información de sus valores máximos, mínimos, medios y desviación estándar, aplicado en buffers de 10, 20, 30, 40, 50, 100, 200, 500 y 1000 m.

Por tanto, el análisis se llevó acabo comparando cada una de las variables limnimétricas versus la Elevación, Orientación, y la Pendiente. Para ello, se utilizó el software RStudio, se crearon tres archivos “.R”, para las tres características morfológicas, estos archivos contenían una matriz de 40 variables en las cuales se obtuvo la matriz de correlación y se procedió a estandarizar las variables, posteriormente se aplicó el ACP. Los parámetros Limnimétricos y características morfológicas son los siguientes:

Tabla 3. Variables Limnimétricos y morfológicas de los lagos, en el Parque Nacional Cajas (PNC).

Variable	Unidad
Área del lago (AL)	m ²
Área de la cuenca (A _c)	m ²
Volumen del lago (VL)	m ²
Longitud de la línea de la costa (LC)	m
Profundidad máxima del lago (Z _{max})	m
Profundidad media del lago (Z _{med})	m
Profundidad relativa (Z _r)	%
Desarrollo de la línea de la costa (D _L)	--
Desarrollo del Volumen (D _v)	--
A _c /AL	--
A _c /VL	--
Características Morfológicas	
Altitud de la cuenca (H _{max} , H _{mean} , H _{min})	m s.n.m.
Pendiente de la cuenca (S _{max} , S _{mean} , S _{min})	%



Aspectos (A_{pmax} , A_{pmean} , A_{pmin})	--
--	----

A continuación se presenta un breve recuento de las definiciones de los parámetros limnimétricos y las características morfológicas. El Área del Lago (AL) está constituida por la superficie inundada incluyendo el área de islas, isletas y lechos rocosos. El Área de la cuenca (A_c) es el área de aporte superficial al lago o laguna. El Volumen del lago (VL) es la capacidad del mismo. La longitud de la línea de costa (LC) corresponde al perímetro del cuerpo de agua. La profundidad media del lago (Z_{med}) es el cociente de VL [L^3] entre AL [L^2]. La profundidad relativa Z_r (%) es la profundidad máxima como un porcentaje del diámetro medio.

El desarrollo de la línea de costa (DL) es la relación entre la longitud de la línea costera y la longitud de la circunferencia de un círculo de área igual a la del lago. Este parámetro es importante porque refleja el potencial para el desarrollo de comunidades litorales, que generalmente tienen una alta productividad biológica. DL es grande para lagos de valles fluviales inundados (Parra *et al.*, 2003):

$$D_L = \frac{LC}{2\sqrt{\pi * AL}} \tag{25}$$

El desarrollo del Volumen (D_v) es una medida de la forma de la salida de la cuenca del lago con respecto a la de un cono. Para la mayoría de los lagos, D_v será mayor que 1 (es decir, una depresión cónica) (Almanza Marroquin *et al.*, 2016). D_v es mayor en lagos poco profundos con fondos planos. Entre los lagos profundos, el D_v será mucho mayor que 1,5 (también en muchas cuencas rocosas). La mayoría de los lagos en rocas fácilmente erosionadas tienen D_v en el rango de 1,0 a 1,5. Los valores extremadamente pequeños están en solo unos pocos lagos con agujeros profundos muy localizados. La acción extensiva de los procesos de tierra tiende a reducir la proporción (Lakewatch, 2001):

$$D_v = \frac{3Z_{med}}{Z_{max}} \tag{26}$$

El parámetro A_c/AL es la relación entre la extensión de la cuenca de drenaje y el tamaño del lago. El parámetro A_c/VL es un índice que relaciona los parámetros tróficos y el aporte de nutrientes desde la superficie de la cuenca hacia el lago; toma valores bajos para lagos que poseen más oligotrofia.



2.6.1 Tratamiento estadístico de datos por medio del Análisis de Componentes Principales (ACP)

El ACP tiene como objetivo reducir la dimensionalidad de un conjunto de datos derivados también de un conjunto numeroso de variables con diferentes grados de correlación, conservando la mayor parte de la variabilidad presente en dichos datos (Jolliffe, 1973). El ACP reduce un conjunto de datos que contiene una gran cantidad de variables a un conjunto de datos que contiene menos variables nuevas. Estas variables nuevas son combinaciones lineales de las originales que se eligen para representar la fracción máxima posible de la variabilidad contenida en los datos originales (Pérez *et al.*, 2015).

El ACP transforma las variables dependientes en una nueva matriz de factores que son linealmente independientes entre sí. Estos nuevos factores independientes son combinaciones lineales de las variables de entrada y contienen toda la información significativa de estas; corresponden a los vectores propios que son denominados componentes principales, mientras que los coeficientes que definen a las componentes son los valores propios de la nueva matriz. El primer componente principal es la suma ponderada que explica la máxima variación posible (varianza), o sea, minimiza la suma de los cuadrados de las distancias a ella de los valores observados. El segundo componente explica la mayor parte de la variación restante. Se tiene por tanto que los componentes se ordenan según la varianza en forma decreciente y son ortogonales entre sí, es decir, son independientes.

En términos generales, el procedimiento adoptado fue el siguiente:

- 1) Se centran y normalizan las variables originales (x_i), tal como se muestra a continuación:

$$W_i = \frac{(x_i - \bar{x}_i)}{\sigma_i} \tag{27}$$

, donde, x_i son las variables originales; \bar{x}_i es la Media de la variable original i ; σ_i es la Desviación estándar de la variable original i . De esta forma, se obtiene una matriz con $N\phi$ filas u observaciones y $N\nu$ columnas o variables estandarizadas.

- 2) Se calcula la matriz de correlaciones R :



$$R=(r_{i,j})=\begin{bmatrix} 1 & r_{1,2} & \dots & r_{1,NV} \\ r_{2,1} & 1 & r_{2,3} & \dots \\ \dots & \dots & 1 & r_{N\emptyset-1,NV} \\ r_{N\emptyset,1} & \dots & \dots & 1 \end{bmatrix} \quad (28)$$

, donde, r_{ij} es la correlación entre las variables W_i y W_j .

3) Se obtiene un nuevo sistema de coordenadas rotando el sistema de ejes W_j de modo que las componentes principales CP_i sean linealmente independientes entre sí, lo que equivale a resolver la siguiente ecuación:

$$\text{Det}[R-\lambda I]=0 \quad (29)$$

, donde, R es la Matriz simétrica de correlación, I es la Matriz de identidad y λ son valores propios o eigenvalores.

Este determinante es un polinomio de grado NV en λ , el cual toma valores diferentes NV entre si $\lambda_1, \lambda_2, \dots, \lambda_{NV}$. El porcentaje de variación explicada por cada componente se calcula como:

$$P_i = \frac{\lambda_i}{NV} \quad (30)$$

Cada λ_i permite obtener un conjunto de NV coeficientes c_{ij} , definidos por:

$$(R-\lambda_i)C_i=0 \quad (31)$$

$$\sum_j c_{ij}^2 \quad (32)$$

, donde, i se refiere a CP_i y j a w_j , C_i es el vector propio unitario asociado a λ_i , la matriz de cambio de ejes está formada por los c_i en las columnas.

4) Se obtienen los componentes principales: si las variables originales están reducidas se define cada componente principal como:

$$CP_i = \sum_{j=1}^{NV} C_{ij} W_j \quad (33)$$

2.6.1.1.1 Evaluación de la precisión del algoritmo de Análisis de Componentes Principales (ACP)



Para comprobar que las correlaciones entre las variables son distintas de cero de modo significativo, se verificó si el determinante de la matriz es distinto de uno, es decir, si la matriz de correlaciones es distinta de la matriz identidad (Hubbard and Allen, 1987).

Si las variables están correlacionadas existen muchos valores altos en valor absoluto fuera de la diagonal principal de la matriz de correlaciones. Además, el determinante es menor que 1 (el máximo valor del determinante es 1 si las variables están in-correlacionadas). El test de Barlett realiza el contraste:

$$H_0=|R|=1 \quad (34)$$

$$H_0=|R|\neq 1 \quad (35)$$

El determinante de la matriz da una idea de la correlación generalizada entre todas las variables. El test se basa en la distribución Chi cuadrado, donde valores altos llevan a rechazar la H_0 . Así, la prueba de esfericidad de Bartlett contrasta si la matriz de correlaciones es una matriz identidad, que indicaría que el modelo factorial es inadecuado (Grossman *et al.*, 2007).

Por último, la representación gráfica de los componentes principales, es un gráfico rotante multidimensional, cuyos ejes principales son mutuamente ortogonales igual a lo que sucede en el plano cartesiano y van en orden natural (x, y, z) que es primer, segundo, tercero, etc., ejes principales, los cuales apuntan al centro de gravedad de la nube de puntos (Kulicz, 1965).

El primer eje principal apunta a la dirección de la más grande variabilidad en la nube de puntos. El segundo eje principal es perpendicular al primer eje principal y captura otro porcentaje de variabilidad que es menor al primero, pero menor a los restantes ejes, lo mismo se repite para los restantes ejes (Montgomery, 2011). Los ejes principales significativos son rotados a partir de los ejes originales, en dirección de la mayor variabilidad de los datos. Habrá tantos ejes principales como variables originales existan. Sin embargo, como ya se ha destacado con anterioridad, serán suficientes los primeros (los que contengan la mayor varianza o energía) para describir la mayoría de los datos originales (Montgomery, 2011)



3 CAPITULO III: RESULTADOS

En esta sección se muestran los resultados principales de las actividades desplegadas en el contexto de la presente investigación: (i) obtención mediante técnicas de teledetección de un mapa temático de uso/cobertura del suelo para el MzC; (ii) estima de la profundidad de los lagos y lagunas del PNC; y (iii) el análisis de la potencial correlación entre variables limnimétricas de los lagos y lagunas del PNC y las propiedades morfológicas de los alrededores de estos lagos y lagunas.

3.1 Mapa temático de uso/cobertura del suelo para el MzC

3.1.1 Producto del método Redes Neuronales Artificiales (ANN)

La **¡Error! No se encuentra el origen de la referencia.** muestra el resultado de los valores del análisis de ensibilidad y de la mejor clasificación obtenida por la red neuronal Perceptrón, la tabla enumera los valores de los parámetros: (i) umbral de contribución que mejora las condiciones iniciales de los pesos en las capas; (ii) tasa de aprendizaje que modifica los pesos de forma iterativa; y (iii) momento de entrenamiento que contrarresta las posibles inestabilidades que se crean por la variación de los pesos y que es importante porque puede acelerar rápidamente el proceso (Kanellopoulos et al., 2010).

Se inició con 100 iteraciones, para alcanzar el error mínimo establecido por (17). El umbral para RMS fue fijado en este estudio como 0,01, propuesto en algunos estudios como (Kavzoglu and Mather, 2003b), en el cual se mencionan que valores entre 0,1 y 0,05, se ajusta de mejor manera a la búsqueda del error mínimo fijado, de ahí que, en nuestro caso el número de iteraciones fue alto. Valores muy altos del umbral de contribución, cercanos a 1, generaron clasificaciones con un mayor grado de generalización y gráficas de entrenamiento con presencia de oscilaciones. Valores entre 0,3 y 0,4 hicieron que la gráfica de entrenamiento de la red neuronal presentase un menor grado de oscilaciones, lo que indica que el error va convergiendo gradualmente.

Por otra parte, valores de la tasa de aprendizaje entre 0,15 y 0,20 redujeron el número de oscilaciones entre iteraciones y produjeron que el cambio de los pesos de las conexiones fuese más suave. Esto proporcionó una



convergencia más rápida alcanzando el error esperado. El momento de entrenamiento aseguró la reducción de las oscilaciones entre iteraciones. Valores entre 0,7 y 0,8 mostraron una disminución del número de oscilaciones

Tabla 4. Parámetros de entrenamiento obtenidos en el análisis de sensibilidad aplicando el método de clasificación Redes Neuronales Artificiales (ANN) para el Macizo de Cajas (MzC).

Nº de iteraciones	Umbral de contribución [--]	Taza de aprendizaje [--]	Momento de entrenamiento [--]	RMS [--]
10	0,2	0,10	0,7	0,05
10	0,3	0,10	0,8	0,05
100	0,3	0,20	0,7	0,05
100	0,3	0,20	0,8	0,05
200	0,4	0,15	0,7	0,05
200	0,4	0,20	0,8	0,01
300	0,4	0,15	0,7	0,05
300	0,3	0,20	0,8	0,01
400	0,4	0,15	0,7	0,05
400	0,3	0,20	0,8	0,01
500	0,4	0,15	0,7	0,05
500	0,3	0,20	0,8	0,01
1000	0,2	0,15	0,7	0,05
1000	0,2	0,20	0,8	0,01
2000	0,4	0,15	0,7	0,05
2000	0,3	0,20	0,8	0,01

Se escogió la función de activación tipo sigmoïdal ya que el aprendizaje fue más estable debido al comportamiento convergente de la función.

Según la Tabla 4, luego de 500 iteraciones, los parámetros tienden a volverse constantes y el valor del error mínimo no se modifica. La Figura 8 muestra la clasificación de uso/cobertura del suelo en el Macizo del Cajas obtenida con el método ANN.

El mapa temático de la Figura 8, corresponde a un raster con resolución de 30 x 30 m², de la clasificación supervisada de ANN. Se obtuvieron 15 clases de cobertura; Bosque Polylepis, Bosque Siempreverde, Camaronera, Humedales, Manglar, Mar, Matorrales, Nubes, Paramo, Paramo sobre roca, Pastizales, Sombras, Suelo Degradado,

Zona Antropogenica. De acuerdo con la misma figura, se observa que el método de ANN, logró clasificar bien, clases como; mar, manglares, camaroneras y cuerpos de agua, a pesar de que las firmas espectrales son similares.

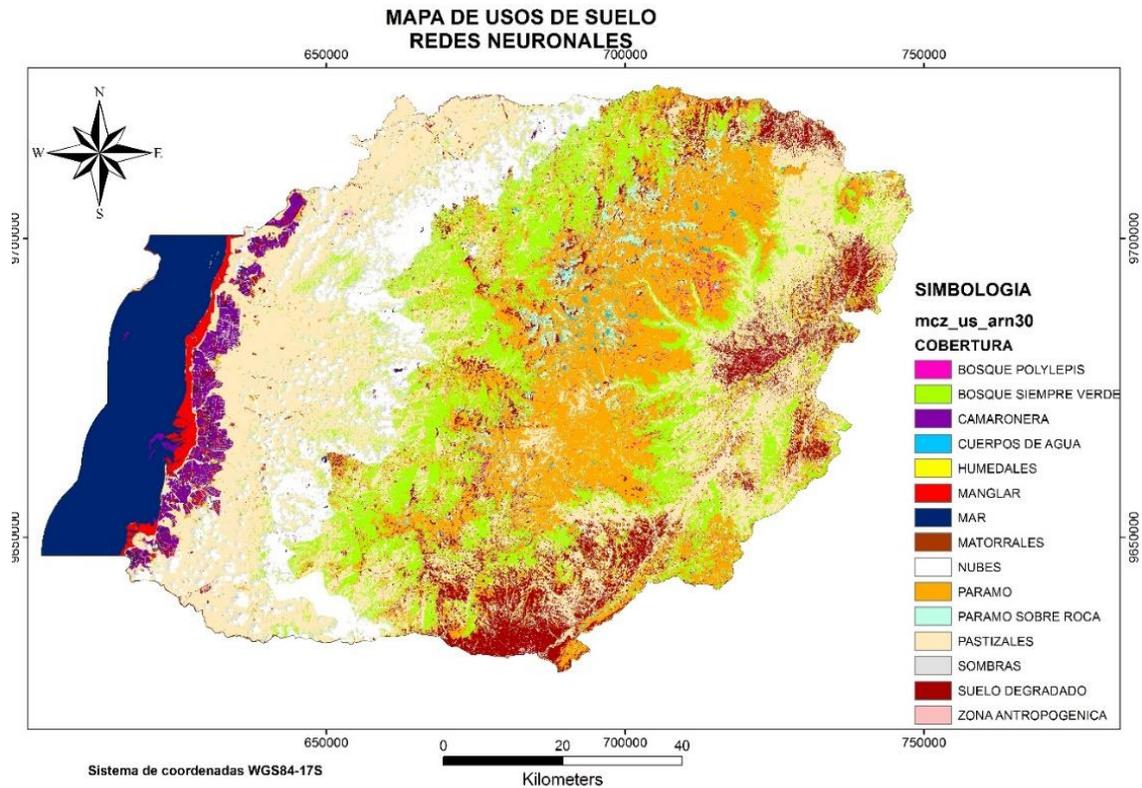


Figura 8. Producto del método de Redes Neuronales Artificiales (ANN) para el Macizo de Cajas (MzC).

3.1.2 Clasificador Máxima Verosimilitud (MV)

Las clases creadas en la clasificación supervisada con MV identificaron que las categorías están especialmente nítidas, en coberturas como; manglares y suelo degradado permitiéndose distinguir entre ellas, excepto las clases de zona antrópica (ZA) y cuerpos de agua (CA), debido a que algunas áreas de estas clases fueron incluidas en clases suelo degradado y camaroneras respectivamente.

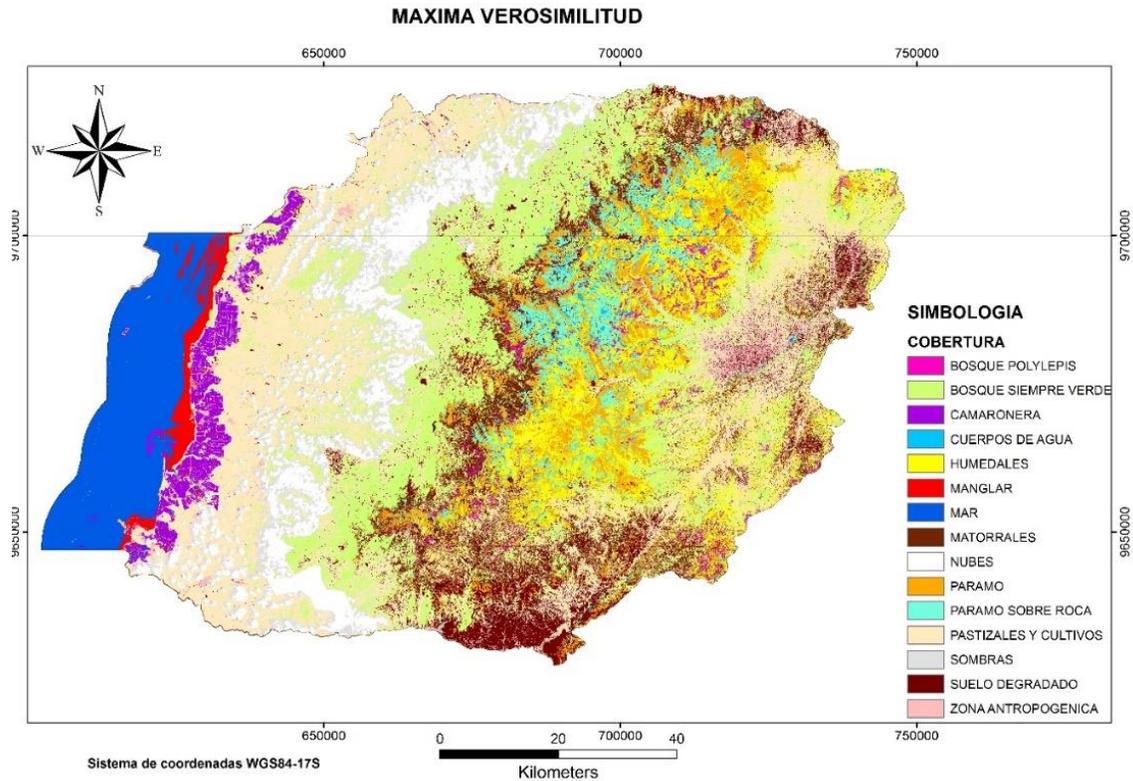


Figura 9. Producto del método de Máxima Verosimilitud (MV) para el Macizo del Cajas (MzC).

3.1.3 Clasificador Mahalanobis (MH)

MH tuvo problemas con la similitud de la firma espectral observada entre algunas clases, sobre todo en los lugares donde predominan los matorrales, mar y manglar.

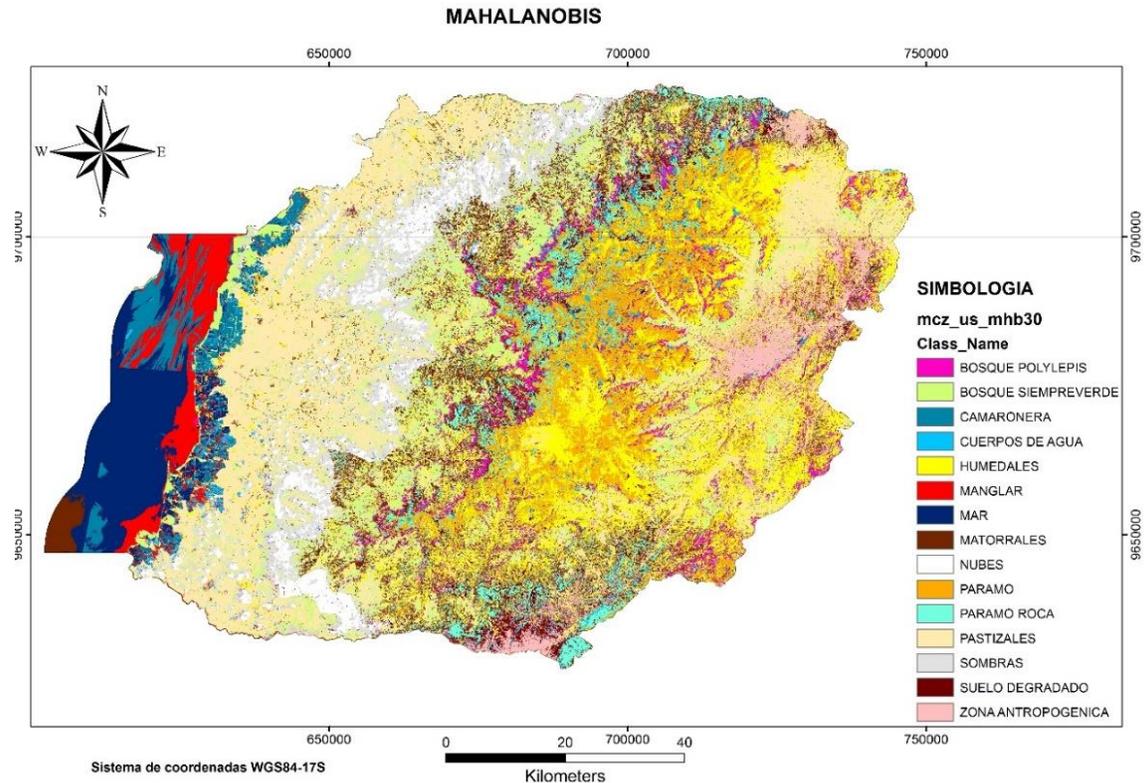


Figura 10. Producto del método de distancia de Mahalanobis (MH) para la el Macizo de Cajas (MzC).

3.1.4 Evaluación de la precisión de los clasificadores

Para realizar la evaluación de la precisión de los clasificadores, se empleó el error relativo absoluto ERA, para lo cual se desarrolló el siguiente procedimiento; Se utilizó la información de control del PNC extrayendo los polígonos de entrenamiento, empleando el comando *extract by mask* en Arc Map 10.1, de tal modo que se evite la superposición de información de resultados de cada cobertura, así las operaciones se basaron únicamente en los píxeles que no se emplearon durante la etapa de entrenamiento. El raster obtenido se muestra en la Figura 11. Se realizó el mismo procedimiento para cada raster obtenido por los métodos ANN, MV y MH, solamente del área del PNC, con el único propósito de contrarrestar la misma información ver Figura 12, Figura 16 y Figura 14.

COBERTURA_

-  BOSQUE POLYLEPIS
-  BOSQUE SIEMPREVERDE MONTANO ALTO
-  CUERPOS DE AGUA
-  HUMEDAL
-  MAR
-  MATORRALES
-  PARAMO
-  PARAMO SOBRE ROCA
-  PASTIZALES Y CULTIVOS
-  SUELO DEGRADADO
-  ZONA ANTROPOGENICA

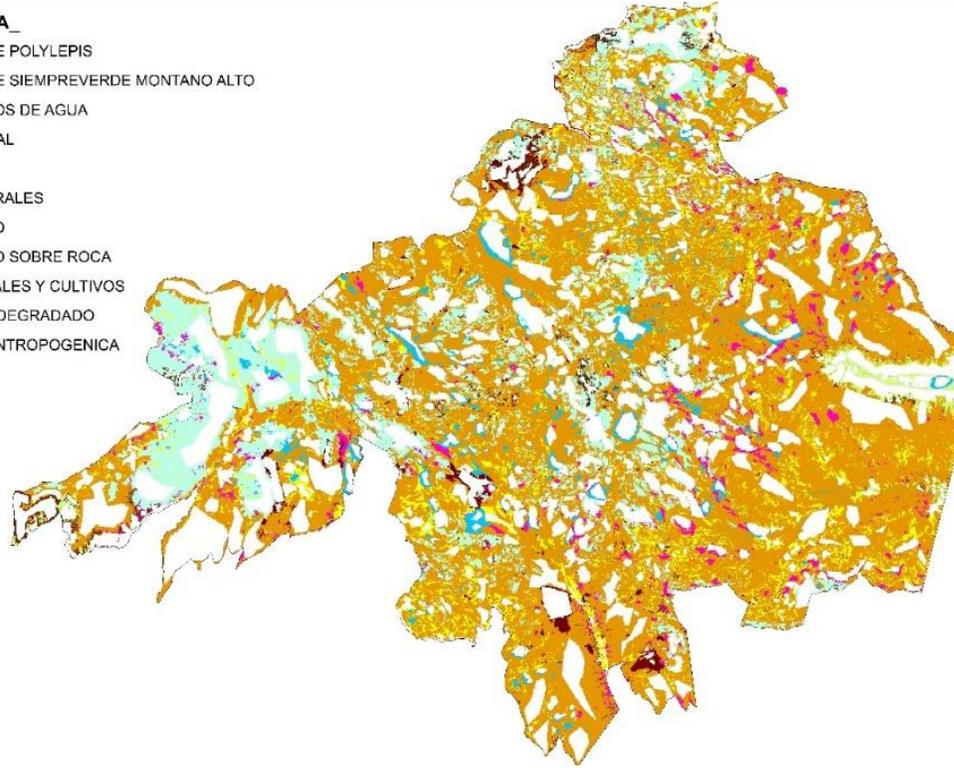


Figura 11. Información de Control del Parque Nacional Cajas (PNC) sin información de los polígonos que se emplearon durante el proceso de clasificación de imágenes.

En el mapa de cobertura del PNC, se muestran 10 categorías de uso/cobertura del suelo, incluyendo la cobertura del mar como límite de la biosfera.

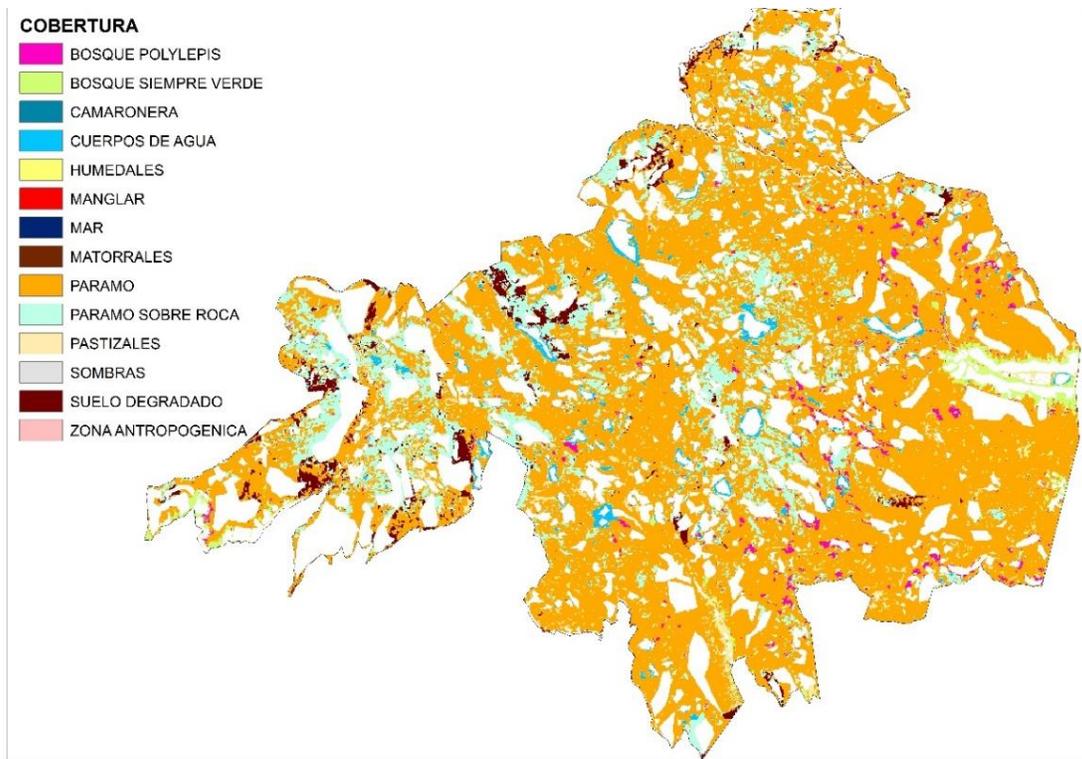


Figura 12. Producto del método de Redes Neuronales Artificiales (ANN) para el Parque Nacional Cajas (PNC).

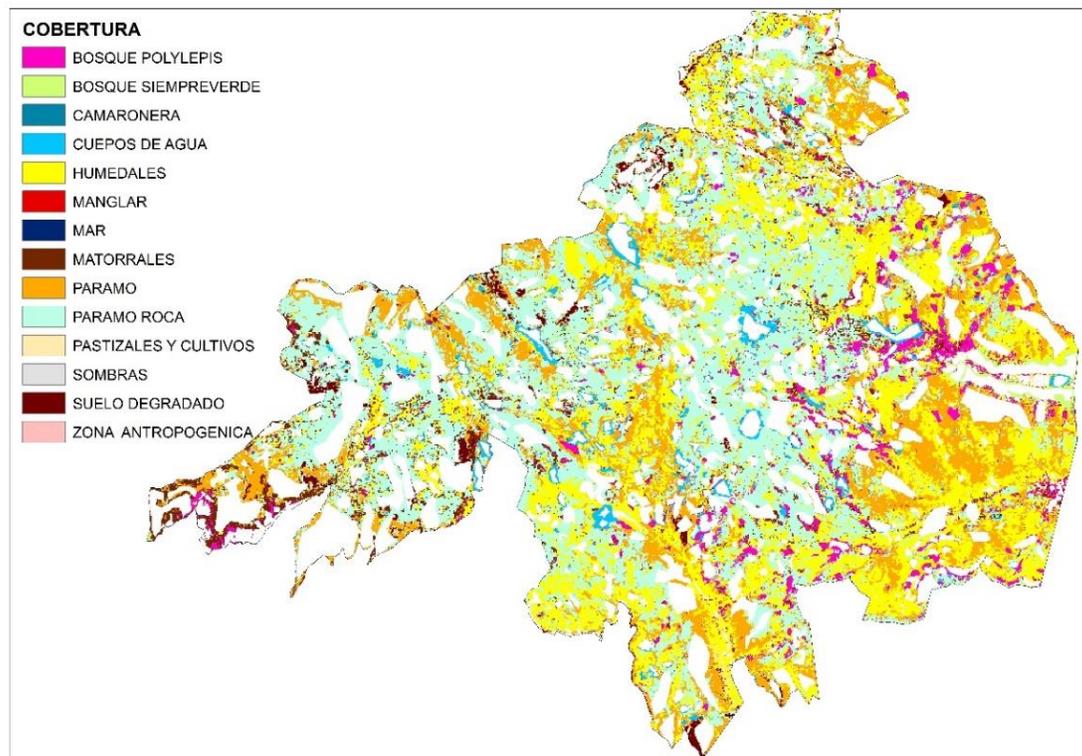


Figura 13. Producto del método de Máxima Verosimilitud (MV) para el Parque Nacional Cajas (PNC).

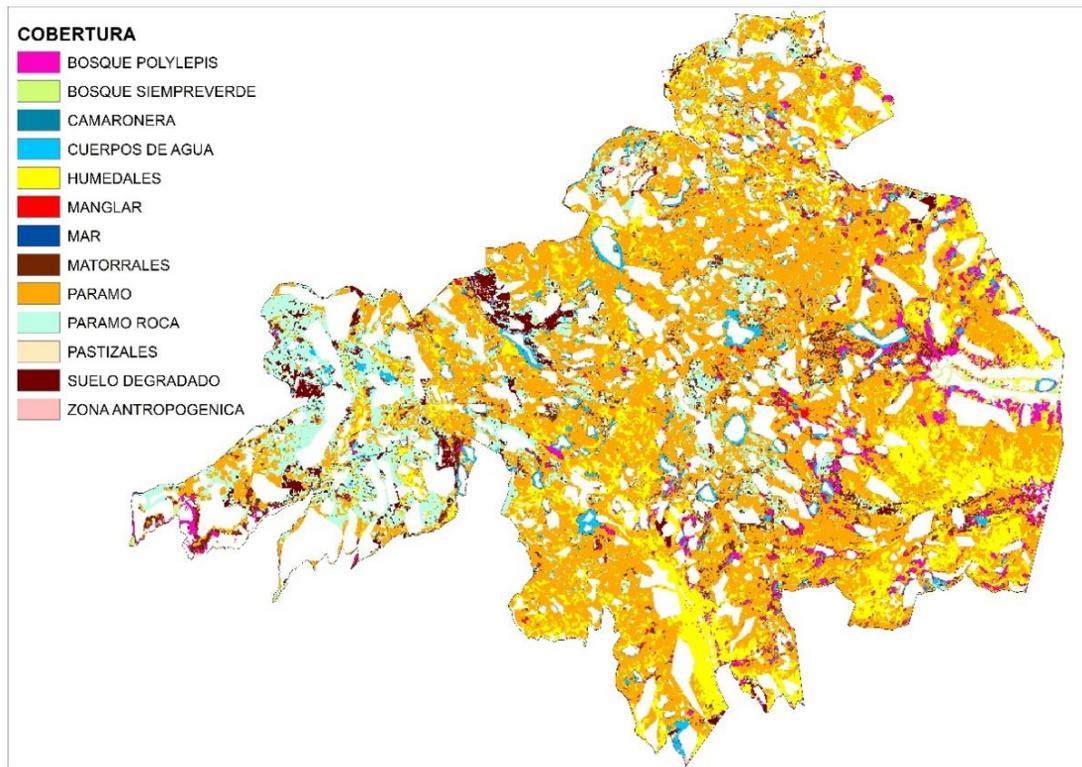


Figura 14. Producto del método de distancia de Mahalanobis (MH) para el Parque Nacional Cajas (PNC).

El método de MV, clasifica el uso del suelo en 14 categorías en PNC, incluyendo coberturas como camaronera, manglar y sombras que evidentemente no pertenecen al área de validación. Debido al comportamiento espectral similar de algunas coberturas, el algoritmo de RNA, incluye otras coberturas en el PNC; Camaronera, Manglar y Sombras, los cuales corresponden a áreas muy pequeñas y cercanas a los cuerpos de agua.

Posteriormente, se realizó una reclasificación por cada clase de cobertura, por ejemplo, para la categoría denominada Cuerpos de Agua (CA) se le asignó una descripción numérica, como indica la Tabla 2, es decir, para cada celda clasificada como cuerpo de agua por cualquier método en este caso ANN, se la reclasificó fijando un valor numérico de 4, y el resto de las celdas correspondientes a otras coberturas con el valor numérico de 0, con esto se obtuvieron los raster de la Información de Control del PNC ver Figura 15 y el raster de la clase cuerpos de agua, por el método de ANN (Figura 16). Este procedimiento se realizó para cada método y para cada clase de uso/cobertura.

Para determinar el error absoluto, se aplicaron operaciones aritméticas (álgebra de raster), restando los raster de la Información de control de PNC (Figura 11) y el producto de los métodos de ANN, MV y MH (Figuras 12, 13 y 14), para para ello se utilizó el software ARCMAP 10.1 mediante el comando *raster calculator*. Este proceso se repitió para todas las clases. A manera de ilustración del proceso, la Figura 17 muestra los resultados de la clase cuerpos de agua según el método ANN.

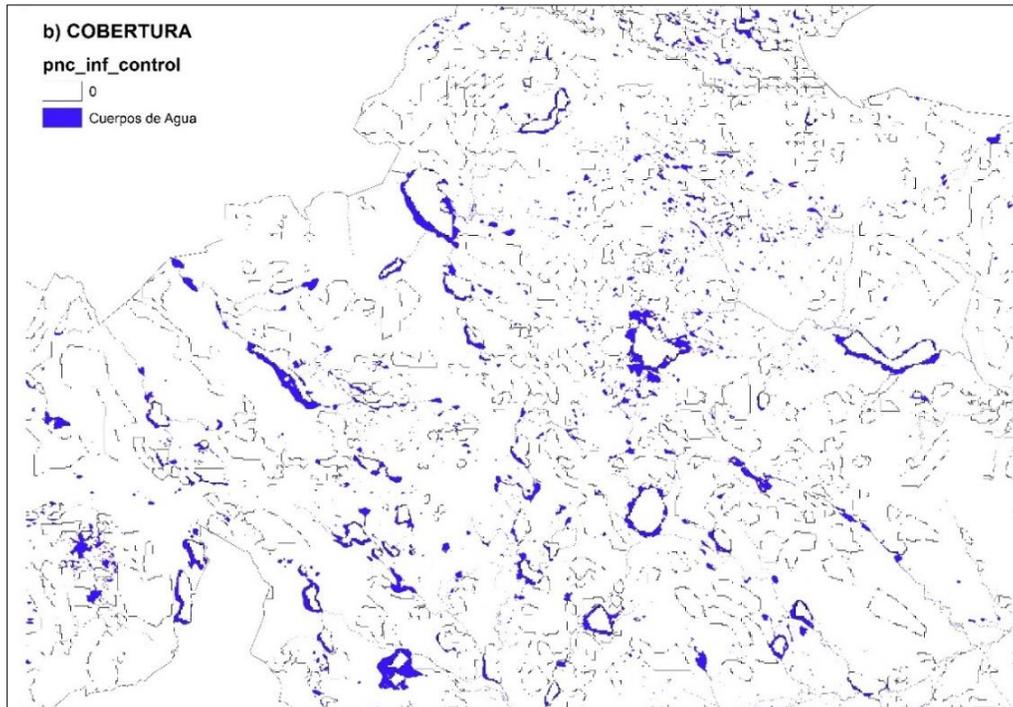


Figura 15. Producto de la cobertura de uso de suelo de la clase Cuerpos de Agua (CA) que se deriva del mapa de Control.

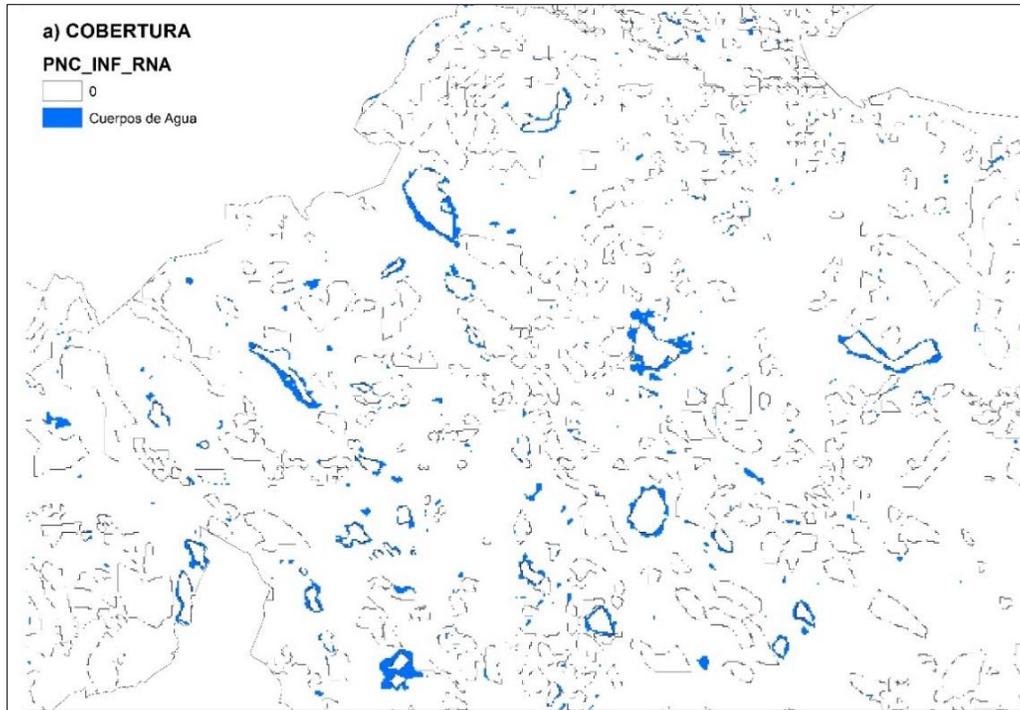


Figura 16. Producto de la cobertura de uso de suelo de la clase Cuerpos de Agua (CA) que se deriva del mapa obtenido por el método de RNA

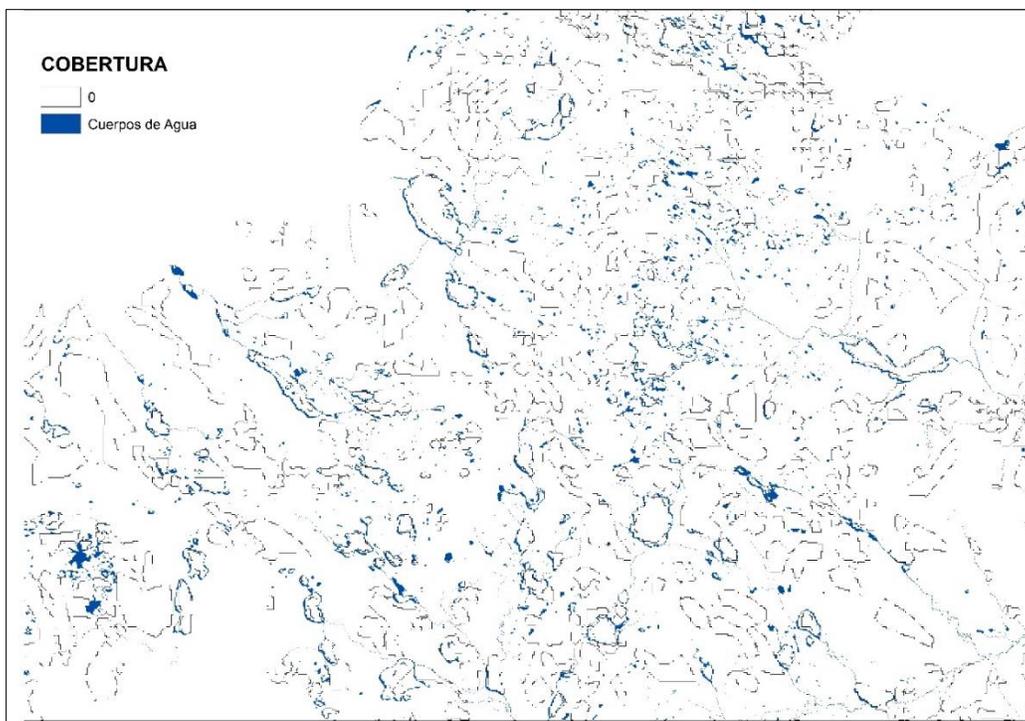


Figura 17. Producto de la diferencia del valor Absoluto (Control-ANN), para la cobertura cuerpos de agua (CA).



Para el cálculo del ERA, se extrajo de cada ráster (Control-ANN) el número de píxeles bien clasificados para cada clase de cobertura como se muestra en la Tabla 5, se indica también el número total de píxeles de cada raster.

La

Tabla 6 detalla el análisis de calidad de los tres métodos de clasificación de las imágenes utilizando la ecuación (19) se obtiene el valor absoluto relativo en fracción.

Tabla 5. Número de píxeles en cada ráster medido de los métodos Redes Neuronales Artificiales (ANN), Máxima Verosimilitud (MV) y Mahalanobis (MH).

Descripción	Control	ANN	MV	MH
Bosque Polylepis (BP)	272765	246680	396807	388699
Bosque Siempreverde (BV)	74793	142833	82987	58920
Camaronera (CAM)	0	1404	22631	4026869
Cuerpos de Agua (CA)	288560	219040	236257	299969
Humedal (HM)	770424	763514	2046728	1530356
Manglar (MG)	0	1707	776177	4204152
Mar (MR)	21420813	12075	833259	9476670
Matorrales (MT)	133785	133905	450260	1819071
Nubes (NU)	0	0	0	0
Páramo Pajonal (PA)	5647277	2458255	4503209	3101383
Páramo sobre Roca (PR)	1420037	1435237	2688590	1334301
Pastizales y Cultivos (PZ)	7319	200821	26513	33733
Sombras (SO)	0	715	180	0
Suelo Degradado (SD)	91590	280479	203394	283308
Zona Antrópica (ZA)	1025	2537	47168	18043
TOTAL:	30128388	5899202	12314160	26575474

Tabla 6. Error relativo absoluto (ERA) calculado en base al número de píxeles medidos en función de los métodos Redes Neuronales Artificiales (ANN), Máxima Verosimilitud (MV) y distancia de Mahalanobis (MH)

Descripción	RNA	MV	MH
Bosque Polylepis (BP)	0,820	1,320	1,29
Bosque Siempreverde (BV)	0,474	0,275	0,196
Camaronera (CAM)	0,005	0,075	13,366
Cuerpos de Agua (CA)	0,727	0,784	0,996
Humedal (HM)	2,534	6,793	5,079
Manglar (MG)	0,006	2,576	13,954



Mar (MR)	0,040	2,766	31,454
Matorrales (MT)	0,444	1,494	6,038
Nubes (NU)	0,000	0,000	0,000
Páramo Pajonal (PA)	8,159	14,947	10,294
Páramo sobre Roca (PR)	4,764	8,924	4,429
Pastizales y Cultivos (PZ)	0,667	0,088	0,112
Sombras (SO)	0,002	0,001	0,000
Suelo Degradado (SD)	0,931	0,675	0,940
Zona Antrópica (ZA)	0,008	0,157	0,060
TOTAL:	1,31	2,72	5,88

La

Tabla 6 indica que el menor error es de 1,31 que corresponde al método ANN. Los ERAs de clasificación asociados a las clases NU, CAM, MG, ZA y MR fueron cercanos a 0. El error asumió valores superiores al 100% para las clases HM, PA y PR. Para las restantes clases los errores fueron inferiores al 100%. En comparación con los otros métodos, la mayoría de los errores asociados a ANN fueron menores, salvo para las clases BV, SD y PZ.

3.1.5 Evaluación del clasificador de uso/cobertura de suelo Post-Clasificación

Una vez elegido el mejor método de clasificación, se aplicaron sobre el producto de ANN los filtros de reducción de ruido y suavizado MJ (Figura 18) y la combinación de SC y CC (Figura 19).

La

Tabla 7 muestra el ERA asociado a la aplicación de cada uno de los filtros referidos. La Tabla sugiere que, en promedio, la mejora que se obtiene luego de la aplicación del filtro MJ con respecto al error del método ANN previo a la aplicación del filtro es marginal (error de 1,25 frente a 1,31, respectivamente).

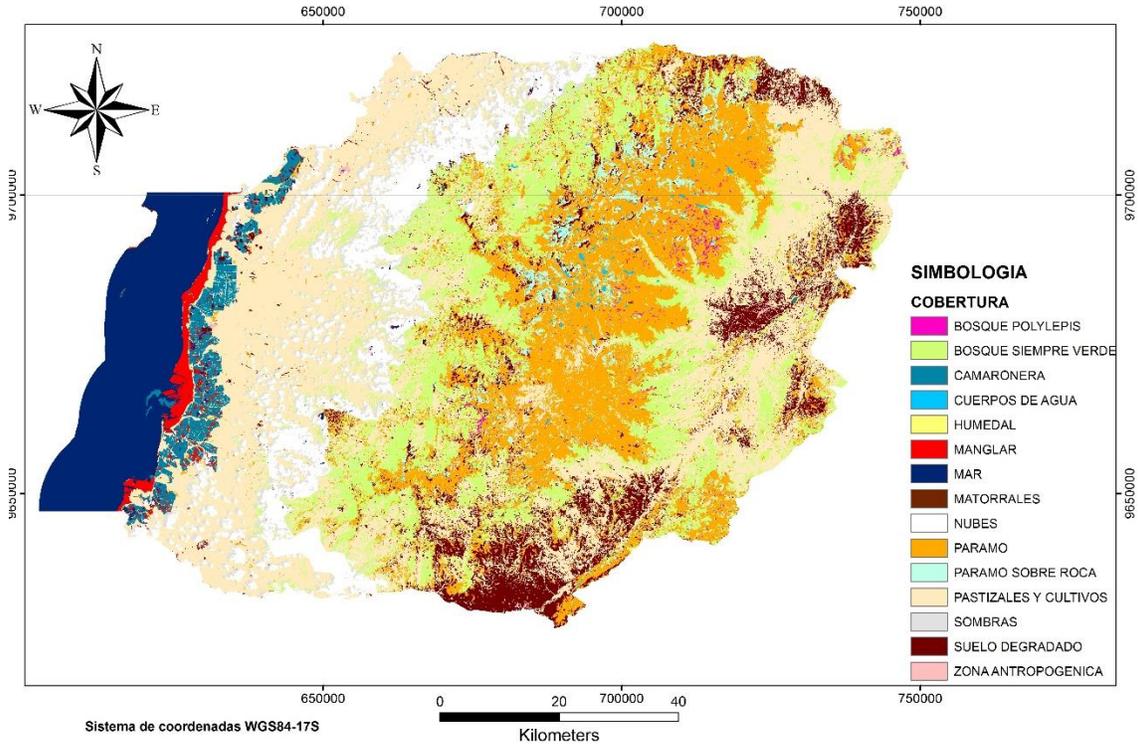


Figura 18. Producto del método de ANN, luego de la aplicación del filtro Majority Filter (MJ).

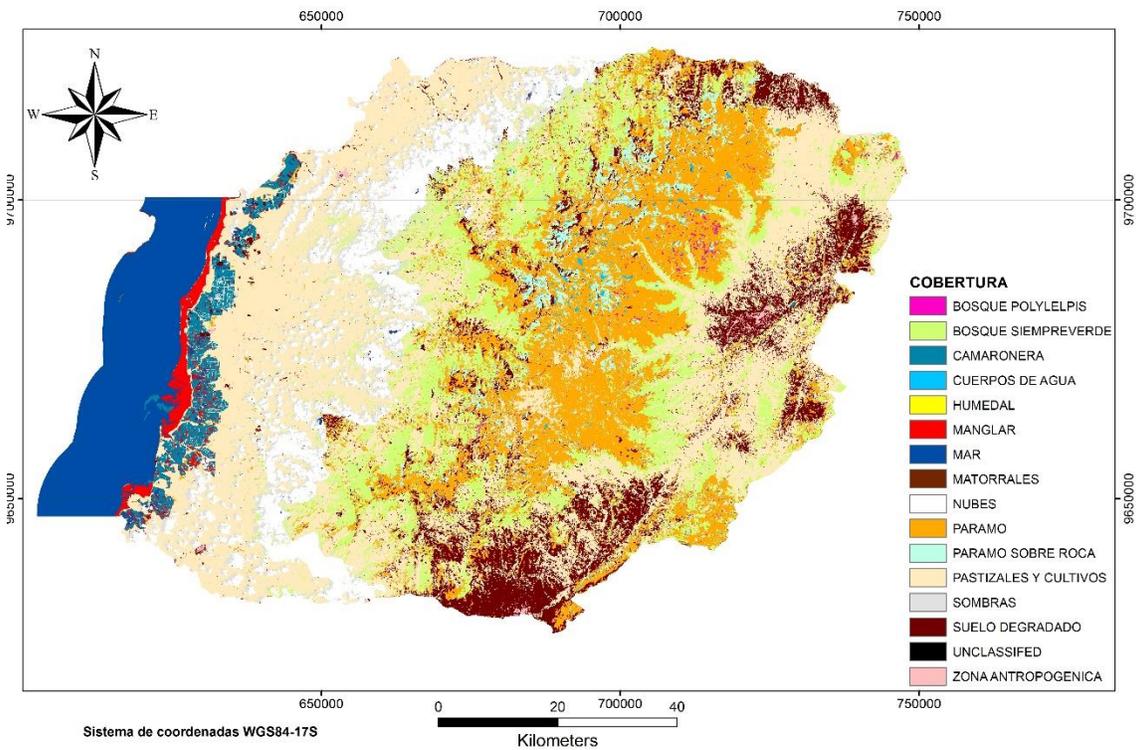


Figura 19. Producto del método de ANN, luego de la aplicación del filtro resultante de la combinación de los procesos Sieve Classes (SC) y Clump Classes (CC).



Tabla 7. Error relativo absoluto (ERA) asociado a la aplicación del filtro Majority Filter (MJ) y el filtro resultante de la combinación de los procesos Sieve Classes (SC) Clump Classes (CC) sobre el producto del método de clasificación ANN.

Descripción	RNA	MJ	SC-CC
Bosque Polylepis (BP)	0,819	0,792	0,820
Bosque Siempreverde (BV)	0,474	0,370	0,325
Camaronera (CAM)	0,005	0,001	0,000
Cuerpos de Agua (CA)	7,275	0,708	0,724
Humedal (HM)	2,534	2,548	2,554
Manglar (MG)	0,006	0,004	0,003
Mar (MR)	0,004	0,027	0,038
Matorrales (MT)	0,000	0,000	0,444
Nubes (NU)	0,000	0,000	0,000
Páramo Pajonal (PA)	8,161	8,047	8,293
Páramo sobre Roca (PR)	4,765	4,928	4,914
Pastizales y Cultivos (PZ)	0,666	0,411	0,735
Sombras (SO)	0,002	0,001	0,002
Suelo Degradado (SD)	0,931	0,845	1,049
Zona Antrópica (ZA)	0,008	0,004	0,007
TOTAL:	1,71	1,25	1,33

El algoritmo ANN tuvo un buen desempeño en la clasificación de cuerpos de agua, (error de 0,73, sin la aplicación de filtro alguno;

Tabla 6); el examen visual respectivo permite distinguir con nitidez, por ejemplo, las lagunas de oxidación de la planta de tratamiento de aguas residuales de la ciudad de Cuenca.

Sin embargo, debido a la gran similitud de las firmas espectrales de ciertas clases, ANN mostró dificultades para distinguir entre Páramo Pajonal y Páramo Sobre Roca, con errores locales de 8,2 y 4,8, respectivamente. Por el contrario, MV tuvo un gran desempeño en la clasificación de Bosque Siempre Verde, Pastizales y Sombras que, por su gran similitud en términos de firmas espectrales, no son fáciles de distinguir.

Las pequeñas áreas antrópicas fueron difíciles de extraer con la resolución de las imágenes utilizadas en el ámbito del presente estudio. En este sentido, las áreas de cultivos y pastizales se extrajeron con más precisión que las áreas urbanizadas y las carreteras.



Finalmente, la

Tabla 6 muestra que el método MH sobreestimó las áreas del mar, manglar y las zonas urbanas, lo cual se refleja en los errores altamente significativos asociados al producto del mismo.

Independientemente del método aplicado, se encontró que la biosfera del MzC se puede identificar en tres principales clases de uso de suelo como son las zonas agrícolas o de actividades socioeconómicas con áreas extensas de camaroneras, plantaciones, pastoreo y pesca. Otro de los usos de suelos es la conservación de páramos y bosques, y la última clase son los asentamientos urbanos, que se consideran en crecimiento.

El clasificador de ANN, tuvo un buen desempeño en la clasificación de cuerpos de agua (CA), esto se pudo constatar en la precisión obtenida y con un examen visual del mapa observándose las lagunas de oxidación, en la Planta de Tratamiento de Aguas Residuales en la ciudad de Cuenca. A pesar del buen desempeño en la predicción de las clases de suelo, el algoritmo de ANN, tuvo dificultades en la clasificación entre el páramo y páramo sobre roca, con errores locales de 8,15 y 4,76 respectivamente, esto debido a la gran similitud de las firmas espectrales de cada clase.

El clasificador de máxima verosimilitud tuvo un gran desempeño en la clasificación de clases como el Bosque Siempre Verde (BV), Pastizales (PZ) y Sombras (SO), que por su gran similitud, tendían a confusión. Las pequeñas áreas antrópicas fueron difíciles de extraer con la resolución de imágenes OLI, aunque las áreas de cultivos y pastizales (PZ) se extrajeron con éxito con más precisión que las áreas urbanizadas y las carreteras. Se encontró que el método MH sobreestimaron las áreas del mar (MR) y manglar (MG) y las áreas urbanas, y este método tuvo un rendimiento dramático en comparación con los otros dos métodos.

Uno de los problemas principales de la clasificación de uso/cobertura de suelo, fue que las clases temáticas de vías y los lechos de río fueron clasificados como áreas edificadas, debido a que sus firmas espectrales son muy similares. Los lechos de ríos contienen una gran cantidad de bloques de rocas, grava y arena, sus firmas son semejantes al hormigón, cubiertas de asfalto y la construcción de las zonas urbanas. Los cursos de agua de ríos estrechos se confunden fácilmente con los tejados de los edificios y se pueden clasificar como áreas urbanas. La clase ríos, proporcionada por ETAPA EP, se extrajo como una capa vectorial separada y se combinó con la capa vectorial de clasificación para eliminar los errores específicos en la clasificación.

Otra dificultad presentada fue la diferenciación entre las tierras agrícolas de las laderas y los bosques interandinos. Alrededor de los asentamientos urbanos, hay parcelas de huertos en vinculación a campos de

cultivos, mostrando similitudes espectrales con los bosques interandinos. Éstas corresponden a la actividad agrícola principal en la región costanera como son: el cacao, la caña de azúcar y el banano.

En la descripción de la clase del mapa se especifica que la categoría cultivos y pastizales (PZ) contiene usos de suelo para la agricultura, ganadería y jardines, incluyendo arrozales, tierras de cultivo irrigadas y secas, caña de azúcar, bananeras etc. Esta clase fue empleada para identificar, comparar y validar mediante visitas de campo a los lugares con mayor dificultad de identificación, mediante técnicas SIG y herramientas de geo-procesamiento, un ejemplo de ello se muestra en la Figura 20, donde se puede apreciar el uso de suelo para la clase Cuerpos de Agua (CA), que ha sido clasificada por ANN.

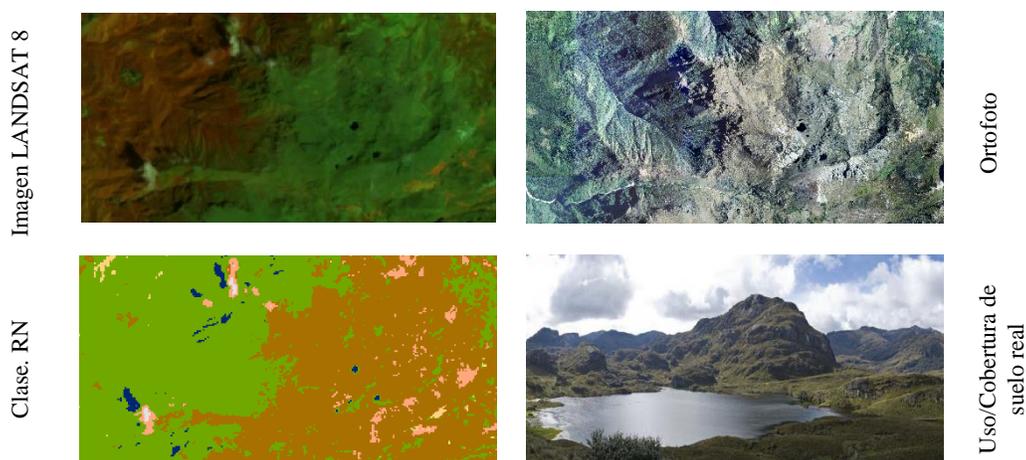


Figura 20. Validación y comprobación de resultados para el producto del método de ANN en relación a la clase “cuerpos de agua”.

3.2 Estima de la Profundidad de lagos y lagunas del PNC.

El registro de control en campo, el valor medio ópticamente de profundidad conocida es de 38,66 m para la banda azul y 15,33 m para la banda roja. La desviación estándar calculada fue de 3,4 y de 2,7 respectivamente. Así los valores de V_s se estiman con 35,3 y 12,7 respectivamente. La radiancia no transformada y transformada se puede observar en las Figura 21 y Figura 22, respectivamente.



Figura 21. La radiancia no transformada de la banda azul original de las imágenes satelitales capturadas de Landsat 8 OLI.

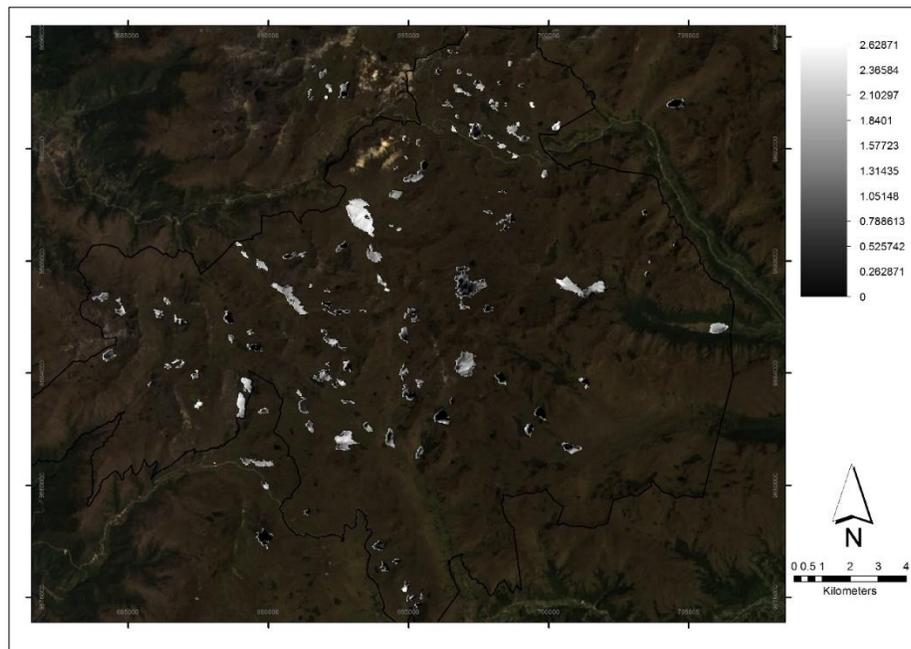


Figura 22. La radiancia transformada de la banda azul original de las imágenes satelitales capturadas de Landsat 8 OLI.

El método empleado en esta investigación es sensible a la calidad del agua y a los parámetros el fondo marino. Para determinar la variabilidad del fondo se realizó un diagrama de dispersión entre las bandas azul y roja como muestra la

Figura 23.

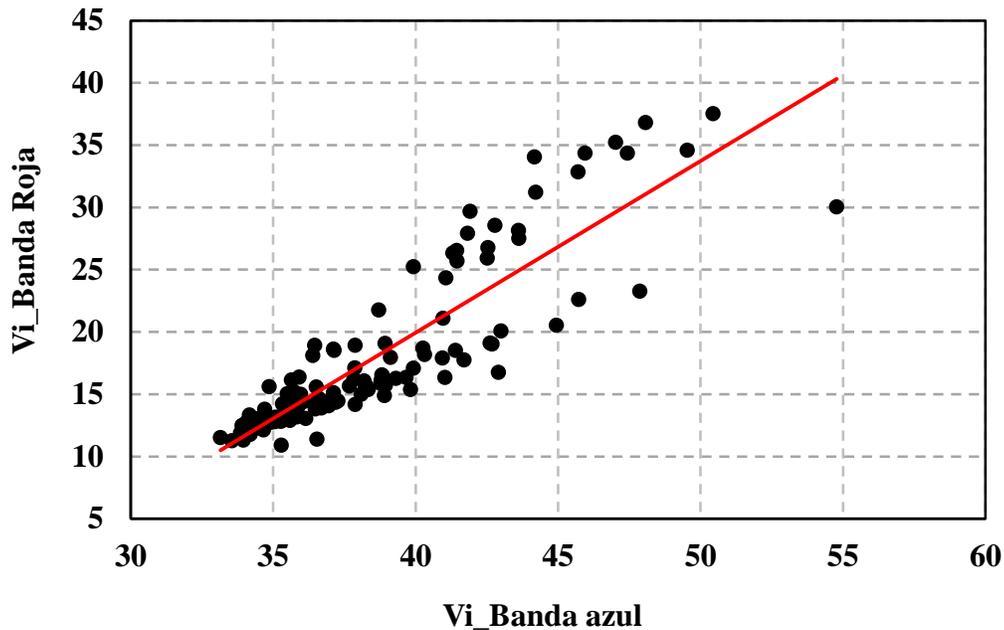


Figura 23. Diagrama de dispersión de los valores de radiancia de las bandas azul y roja.

La

Figura 23 muestra una nube de puntos uniformes a lo largo de la línea, con lo cual se advierte un fondo uniforme, este hecho favorece el ajuste del modelo empírico. Se observa también una tendencia a la atenuación de la radiancia por profundidad, aunque con mayor dispersión para valores bajos de radiancia (zonas profundas) y menor dispersión para valores altos de radiancia (zonas someras). Lo que estaría indicando que la radiancia es afectada por el sustrato del fondo o por los sólidos suspendidos, lo que disminuye la calidad del mapa batimétrico.

Luego de la regresión lineal sobre las bandas del visible, aplicando (22), se obtuvieron los coeficientes de atenuación y de efecto de fondo, que se ilustran en la Tabla 8, con el respectivo coeficiente de correlación.

Tabla 8. Coeficientes de atenuación y de efecto de fondo, así como, de la respectiva correlación asociada a la regresión lineal sobre las bandas del visible.

Banda	$-\frac{1}{2k_a}$	$\frac{1}{2k_a} \ln(V_0)$	r
Azul	-4,73	20,69	0,22
Roja	-6,66	23,57	0,40



En la Figura 24 y Figura 25 se muestra la regresión lineal para las bandas azul y roja.

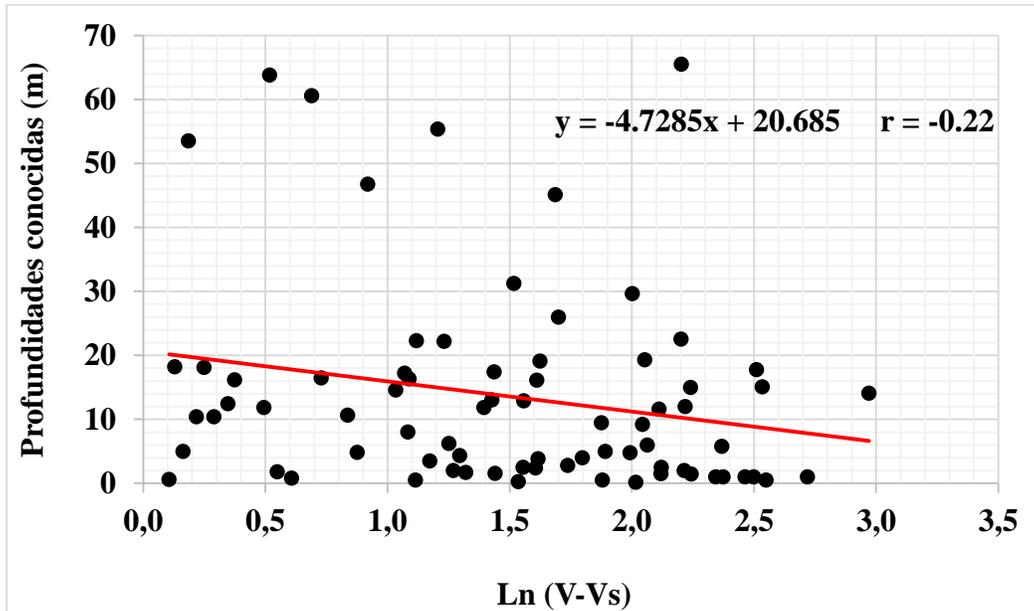


Figura 24. Regresión entre las profundidades conocidas y la banda azul transformada.

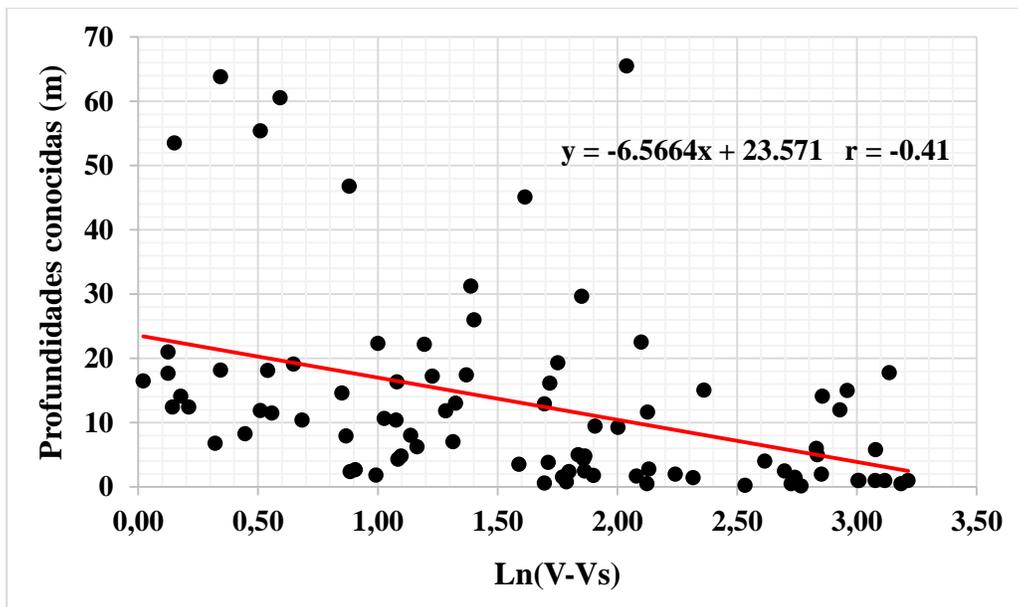


Figura 25. Regresión entre las profundidades conocidas y la banda roja transformada.



Los resultados del análisis de varianza calculada para estudiar la significancia del algoritmo SB se muestran en las siguientes tablas.

Tabla 9. Estadísticas de la Regresión Banda Azul

Parámetro	Valor
Coefficiente de correlación múltiple (r)	0,22
Coefficiente de determinación R ²	0,048
R ² ajustado	0,035
Desviación típica	15,5
Nº de profundidades Simuladas	75

Tabla 10. Estadísticas de la Regresión Banda Roja.

Parámetro	Valor
Coefficiente de correlación múltiple	0,41
Coefficiente de determinación R ²	0,165
R ² ajustado	0,155
Desviación típica	13,7
Nº de profundidades Simuladas	87

Los coeficientes de correlación indican una relación inversa entre los valores de las bandas y las profundidades conocidas. El coeficiente de determinación obtenido es de 4,8% y 16,5% de la varianza en las profundidades conocidas dependientes de las bandas transformadas. La calidad del ajuste en ambos casos es pobre. Para establecer el grado de significancia de las bandas azul y roja, se obtuvieron los valores de las pruebas estadísticas Fisher y t-estadística, las cuales se resumen en las siguientes tablas, tanto para la banda azul como para la banda roja.

Tabla 11. Análisis de la Varianza, Banda Azul.

	Grados de libertad	Suma de cuadrados	Promedio de los cuadrados	F	Valor crítico de F
Regresión	1	891,43	891,43	3,71	0,058
Residuos	73	17544,72	240,34		
Total	74	18436,15			



	Coeficientes	Error típico	Estadístico t	Probabilidad	Inferior 95%
Intercepción	20,685	4,069	5,084	2,75735E-06	12,576
Profundidad Simulada	-4,728	2,455	-1,926	0,058	-9,622

Tabla 12. Análisis de la Varianza, Banda Roja.

	Grados de libertad	Suma de cuadrados	Promedio de los cuadrados	F	Valor crítico de F
Regresión	1	3150,59	3150,59	16,80	9,44418E-05
Residuos	85	15937,34	187,50		
Total	86	19087,93			

	Coeficientes	Error típico	Estadístico t	Probabilidad
Intercepción	23,57	2,98	7,91	8,71E-12
Profundidad Simulada	-6,57	1,60	-4,10	9,44E-05

De acuerdo con el valor de F obtenido la regresión global para la banda azul no es significativa, pero para la banda roja es significativa. Por otro lado, el valor del coeficiente t muestra que la banda azul no es significativa, pero es significativo para la banda roja. Ambos estadísticos con un nivel de confianza de 95%. Por lo tanto, determina que la regresión entre la banda azul transformada y las profundidades conocidas no es significativa. Utilizando el algoritmo a través de la ecuación (22) para la banda roja y azul se obtiene las profundidades de los lagos como se muestra la Figura 26 y Figura 27.

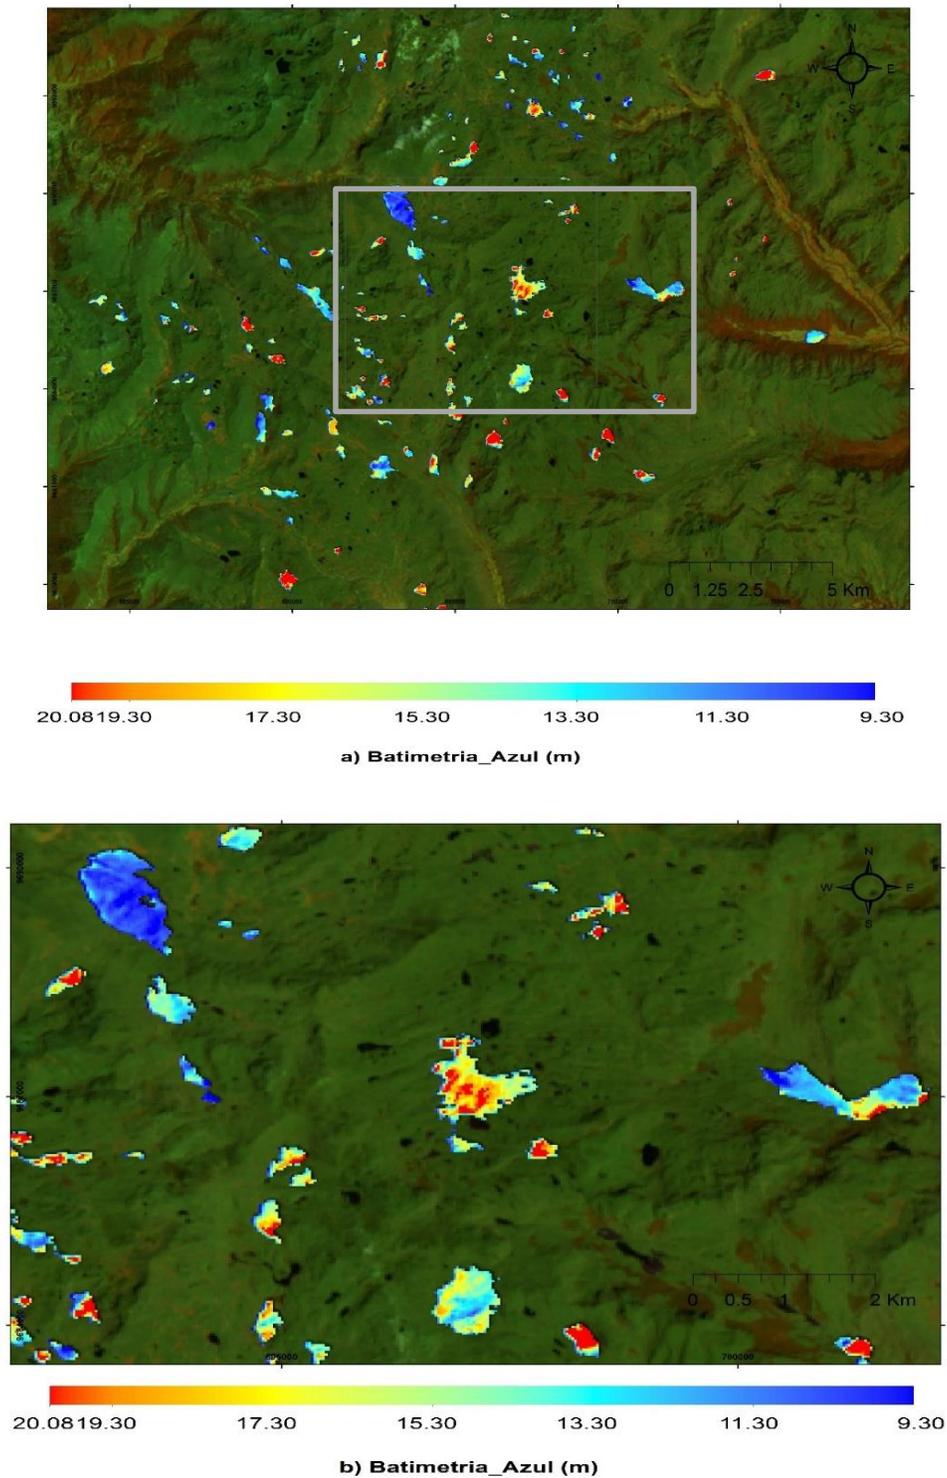
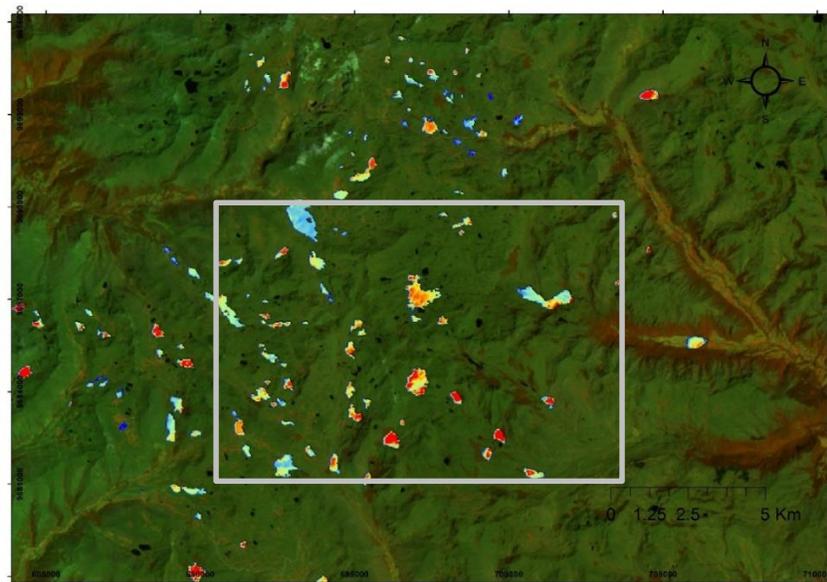
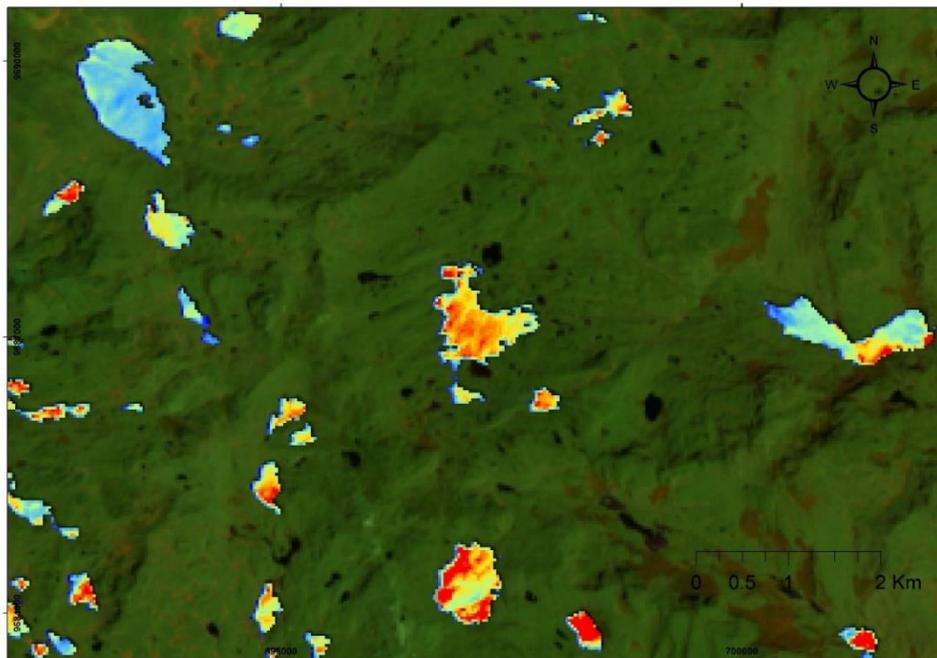


Figura 26. Resultados de las profundidades de los lagos del PNC empleando la banda (azul). (a) Vista global; y (b) detalle de la región señalada en (a). La escala de colores es la misma en ambos casos.



a) Batimetria_Roja (m)



b) Batimetria_Roja (m)

Figura 27. Resultados de las profundidades de los lagos empleando la banda (roja), en el PNC. El marco rectangular muestra en la figura 30 a), detalla a mayor escala los resultados. En la figura 30 b). Se debe tener en

cuenta que el mismo código de color se ha aplicado en ambas figuras.

3.2.1 Evaluación de la precisión de la estima de las profundidades

En el mapa los intervalos de 25 m a 70 m muestran valores mínimos de radiancia y cualquier reflectancia detectada se debe principalmente a los efectos de la dispersión. Se prepararon histogramas de frecuencias con la información contenida en la Tabla 13. Los histogramas se muestran en la

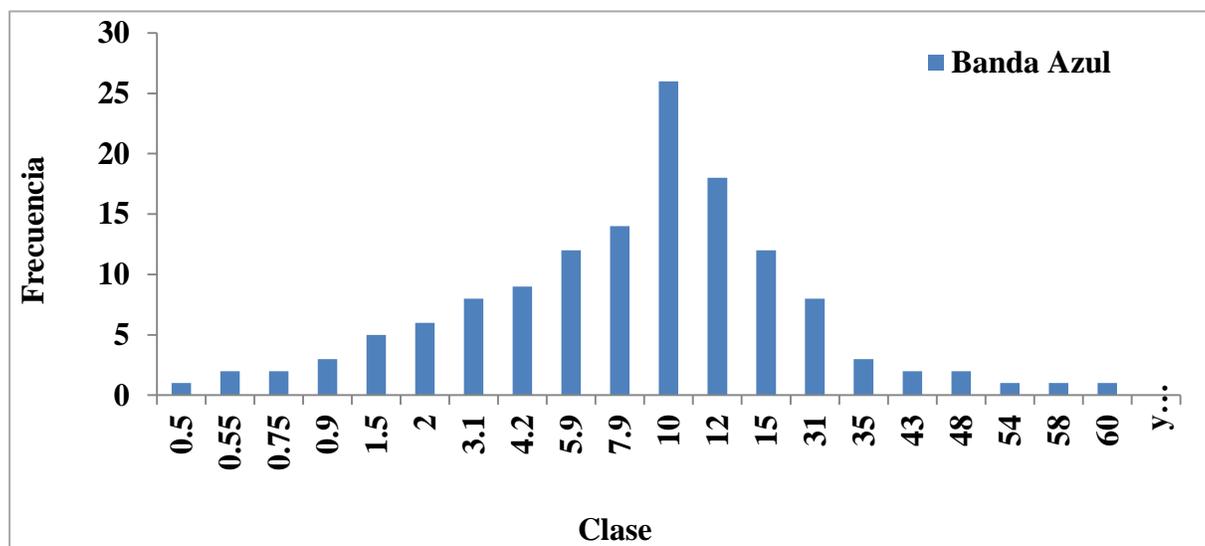


Figura 28 y la Figura 29.

Tabla 13. Marcas de clase para las profundidades del Histograma banda azul y banda roja.

Banda Azul		Banda Roja	
Clase	Frecuencia	Clase	Frecuencia
0,5	1	0,5	2
0,55	2	0,65	2
0,75	2	1	3
0,9	3	1,3	4
1,5	5	2	6
2	6	2,5	7
3,1	8	3,1	9
4,2	9	4,2	11
5,9	12	5,9	18
7,9	14	8	17
10	26	10	14
12	18	11	10

	15	12	13,5	9
	31	8	15	7
	35	3	18	5
	43	2	30	4
	48	2	35	1
	54	1	40	1
	58	1	43	2
	60	1	46	1
y mayor...	0		50	1
			60	2
			y mayor...	0

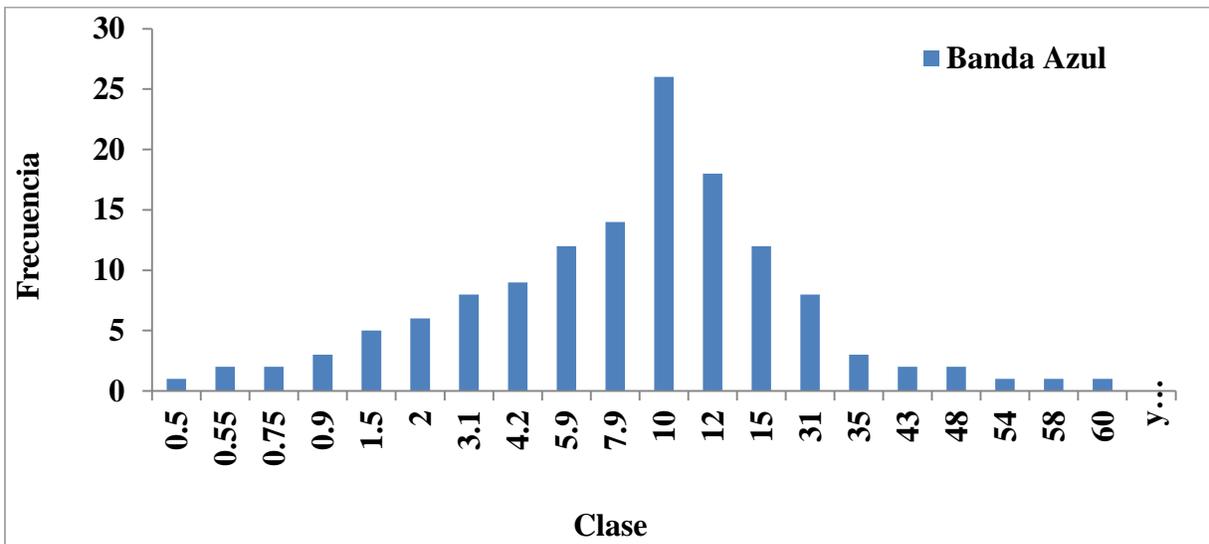


Figura 28. Histograma de profundidades obtenidas por el algoritmo de banda única (banda azul).

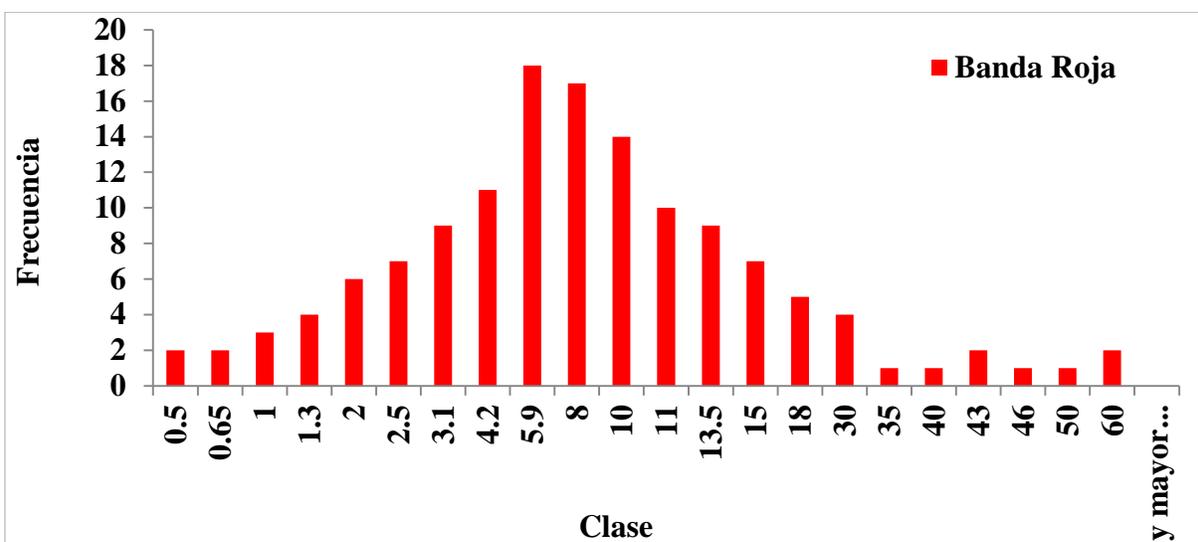


Figura 29. Histograma de profundidades obtenidas por el algoritmo de banda única (banda roja).

De las frecuencias obtenidas en cada histograma se clasificó a los lagos como; Grupo de lagos buenos y Grupo de lagos malos, es decir aquellos en los cuales los residuos absolutos no eran mayores a 2 m. A continuación, se muestran los grupos de lagos clasificados como buenos (Tabla 14 y Tabla 15), para los resultados obtenidos por las dos bandas, el grupo de lagos malos se adjunta en los anexos.

Tabla 14. Grupo de Lagos bien clasificados, por el algoritmo de banda única (azul).

Nombre	Tipo	Altitud (m s.n.m.)	Área (ha)	Profundidad (m)		Abs_res (m)
				Observada	Estimada	
San Antonio 2	Laguna	3721	2,26	5,00	5,21	0,21
Tintacocha	Lago	3679	14,51	1,51	19,85	0,34
Llaviucu	Lago	3152	18,89	16,49	15,95	0,54
Napalé Vía	Lago	3945	3,21	12,91	13,56	0,65
Lagunaloma o Verdecocha	Lago	3837	0,26	2,95	3,64	0,69
Ventanas	Lago	3913	34,26	9,24	10,10	0,86
De la Cascada	Lago	3967	1,96	23,94	23,04	0,90
Cuchichaspana Chica	Lago	3972	3,88	18,11	16,97	1,14
Botacocha	Lago	3839	4,78	14,59	15,76	1,17



San Antonio 1	Laguna	3846	1,24	5,00	3,80	1,20
Cardenillo	Lago	4137	2,27	16,17	17,41	1,24
Potro muerto	Lago	3897	4,33	22,46	20,93	1,53
Hato de chocar 2 o Tintacocha	Lago	3968	9,27	16,34	14,78	1,56
Tinguercocha 1	Lago	3895	13,13	13,05	14,62	1,57
Ira de Sunincocha	Laguna	3752	2,72	1,00	2,86	1,86
Ojo de Osohuaico	Lago	3878	4,70	17,44	15,57	1,87
Chusalongo 1	Lago	3778	5,24	11,85	13,84	1,99

Tabla 15. Grupo de Lagos bien clasificados, por el algoritmo de banda única (roja).

Nombre	Tipo	Altitud (m s.n.m.)	Área (ha)	Profundidad (m)		Abs_res (m)
				Observada	Simulada	
Tinguercocha 1	Lago	3895	13,13	13,05	13,34	0,29
Botacocha	Lago	3839	4,78	14,59	14,08	0,51
Napalé Vía	Lago	3945	3,21	12,91	13,42	0,51
Chuspihuaycu	Lago	3578	9,26	20,65	20,08	0,57
Trensillas	Lago	3997	7,92	19,36	20,08	0,72
Totoracocha	Lago	3583	15,42	17,69	18,46	0,77
Chusalongo 4	Lago	3764	3,41	19,29	20,08	0,79
Quimsacocha 1	Lago	3827	7,75	20,98	20,08	0,90
Cuchichaspana	Lago	3962	8,03	17,76	18,76	1,00
Patoquinuas	Lago	3800	5,99	17,90	18,92	1,02
Chusalongo 1	Lago	3778	5,24	11,85	13,06	1,21
Quinuascocha	Lago	3894	10,55	15,75	17,16	1,41
Patos Colorados	Lago	3946	6,28	18,51	19,98	1,47
Dos Choreras	Lago	3690	16,50	18,56	20,08	1,52
Marmolcocha	Lago	3926	1,37	9,47	11,19	1,72
Ingacocha 1	Lago	3958	4,42	11,62	9,90	1,72
Ventanas	Lago	3913	34,26	9,24	10,96	1,72
Derrumbo Amarillo	Lago	4036	1,67	18,22	20,08	1,86
Cardenillo	Lago	4137	2,27	16,17	14,29	1,88

De la base de datos original, 29 lagos se clasifican como lagos someros, es decir, con profundidades menores a 4 m. Para el grupo de lagos buenos, las profundidades observadas se encuentran entre los 10 m y los 20 m. El



error promedio en lagos someros es de 10 m. Por otra parte, las profundidades del grupo de lagos malos está entre los 40 m y los 70 m. El error promedio en lagos profundos es de 58 m.

En este contexto, la frecuencia del error es de 8 m a 10 m en 26 lagos cuyas profundidades varían entre los pocos metros y los 50 m y cuyas superficies no superan las 10 ha. Se ha observado además que la ubicación geográfica aparentemente no tiene ninguna incidencia particular sobre los errores obtenidos al aplicar el método señalado sobre la banda azul.

Con respecto a las profundidades obtenidas, mediante el análisis de la banda roja, que se encuentran en el grupo de lagos bien clasificados, estas van desde los 10 m a 20 m. El error promedio absoluto encontrado en lagos someros es de 6,6 m, y en lagos profundos es de 29,8 m. Las profundidades de los lagos mal clasificados, son mayores a los 30 m.

Las áreas de los lagos con frecuencias de error de 4 m a 6 m, no superan las 10 ha, lo que indica que no existe un patrón definido entre el área del lago y la estimación de la profundidad del lago. Además se ha observado que la ubicación geográfica aparentemente no tiene ninguna incidencia particular sobre los errores obtenidos al aplicar el método señalado sobre la banda roja.

3.3 Análisis de la potencial correlación entre variables limnimétricas de los lagos y lagunas del PNC y las propiedades morfológicas de los alrededores de estos cuerpos de agua

La cantidad de lagos en el análisis de PCA fue de 145. Este conjunto de lagos abarca un área extensa en el PNC, ubicándose en zonas de alta montaña rodeados de fuertes pendientes, con ciertas excepciones. En la Tabla 16 se muestran las descripciones estadísticas de los diferentes parámetros morfo-métricos que han sido evaluados.

Tabla 16. Principales estadísticos de los diferentes parámetros limnimétricos de los lagos.

Parámetro	Nº Lagos	Media	Mediana	Rango	Rango Inter-cuartil
Área (A; m ²)	145	78612	43288	2586 - 774775	92706 - 22742
Volumen (V; m ³)	145	944912	128472	267 - 22465324	628724 - 26482
Profundidad media (D _{mean} ;m)	145	5,66	3,58	0,05- 31,22	7,41 - 1,36
Altitud (H; msnm)	145	3920	3940	3152 - 4294	4009 - 3834
Pendiente* (S _{max1000} ; °)	145	72,75	73,2	57,20 - 81,80	76,30 - 70,30
Orilla (Sh;m)	145	1,68	1,64	1,12 - 3,103	1,85 - 1,44
Aspecto* (Asp _{med1000})	145	165,7	165,3	125 - 215,2	181,8 - 150,3



Leyenda: * Pendiente máxima en una zona de 1000 m de ancho fuera de la orilla del lago. * Aspectos medios en una zona de 1000 m de ancho fuera de la costa del lago.

De acuerdo con los resultados obtenidos, el 50% de los lagos son medianos, la dispersión de las profundidades está en los 6,1 m. Por su parte, la altitud máxima alcanza los 4294 m s.n.m, y el 75% de los lagos se encuentran sobre los ± 3800 m s.n.m. Cabe mencionar que los lagos se encuentran en cuencas donde las pendientes en su mayor parte sobrepasan los 75° , lo cual coincide con los parámetros derivados de los mapas.

Para el análisis de correlación el conjunto de datos se dividió en tres subconjuntos en los cuales se incluían las variables de forma y geométricas de los lagos con los parámetros de Aspecto, Altitud y Pendientes, que se calcularon en zonas periféricas a los lagos delimitadas mediante buffers de 10, 20, 30, 40, 50, 100, 200, 500 y 1000 m de ancho.

Se realizó una regresión lineal simple, con la finalidad de obtener a priori una vista general de la dispersión de las variables. Para mantener la extensión de este trabajo dentro de límites razonables, la

Figura 30a, Figura 30b y Figura 30c muestran las gráficas de la regresión, únicamente para la variable profundidad máxima versus altitud, orientación y pendiente, con un buffer de 500 m de ancho. Sin embargo, se presentan los resultados de las 11 variables limnológicas analizadas frente a los parámetros morfológicos de los lagos y lagunas en el Anexo 3. Los resultados muestran que no existe una correlación directa entre las variables limnimétricas y los parámetros morfológicos.

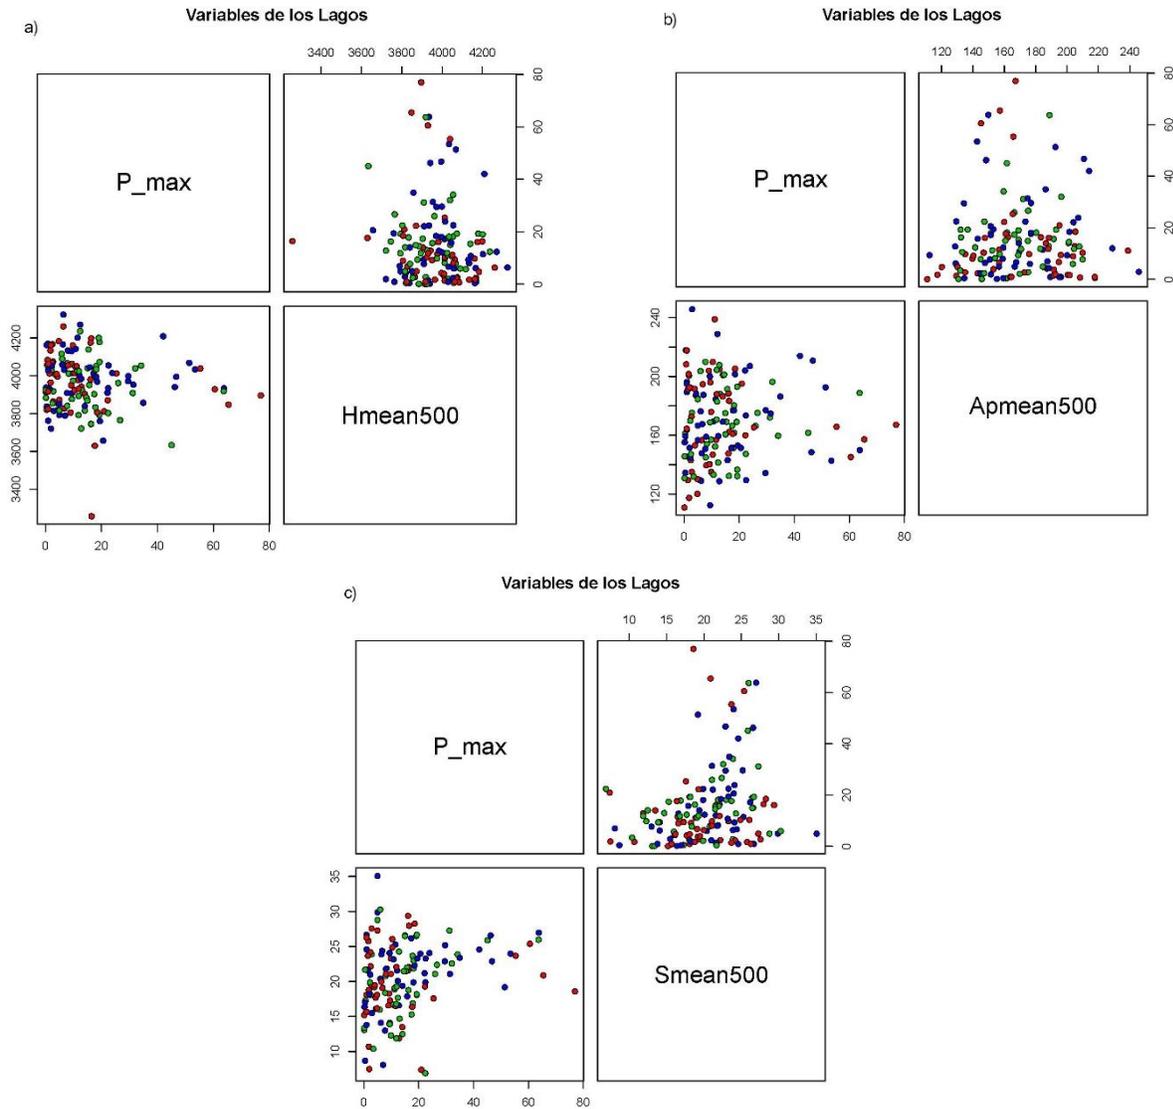


Figura 30. Gráficos de dispersión entre profundidad máxima de los lagos versus variables morfológicas calculadas en el buffer de 500 m de ancho: (a) elevación media; (b) orientación media (aspecto); y (c) pendiente media.

Para el cálculo de las componentes principales (CP), primero se realizó la comprobación de si la base de datos debe ser tratada como una matriz de correlación (datos estandarizados) o matriz de covarianza (datos crudos), mediante el cálculo de la varianza. En el presente caso dicho valor estadístico es igual a 1, y el cálculo de CP, se lo realiza mediante una matriz de correlación. A partir de esta matriz, se obtienen los valores propios y las varianzas. Además se calculan los componentes principales, y se obtiene la curva de referencia del error, que

refleja la influencia del error de muestreo. El número de componentes a retener se indica mediante el punto en el que el gráfico de valores propios de los datos empíricos se cruza con el de la curva de referencia, y en los que, el valor de la varianza tiene mayor importancia. En este estudio, se escogen las componentes principales 1 y 2, como muestran la Figura 31, Figura 32 y Figura 33, para los parámetros morfológicos de elevación, orientación, y pendiente. Los valores de las varianzas se muestran en la Tabla 17.

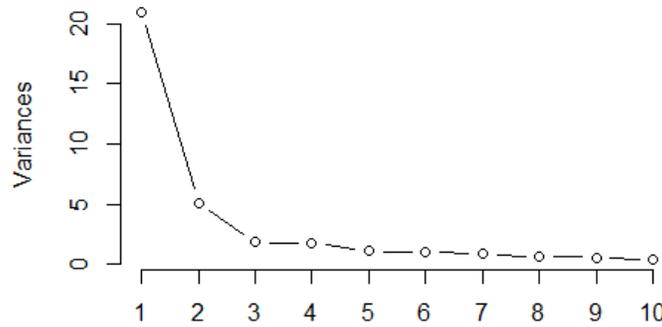


Figura 31. Curva de referencia del error, del parámetro elevación.

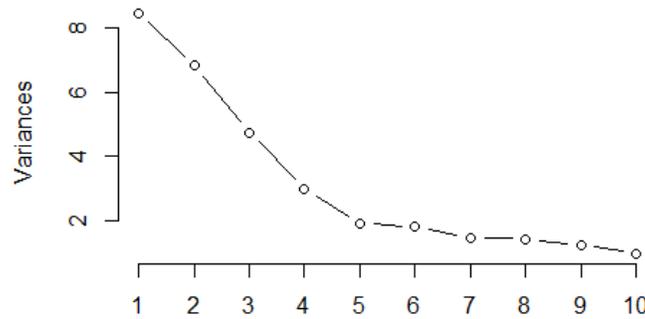


Figura 32. Curva de referencia del error, del parámetro orientación (aspecto).

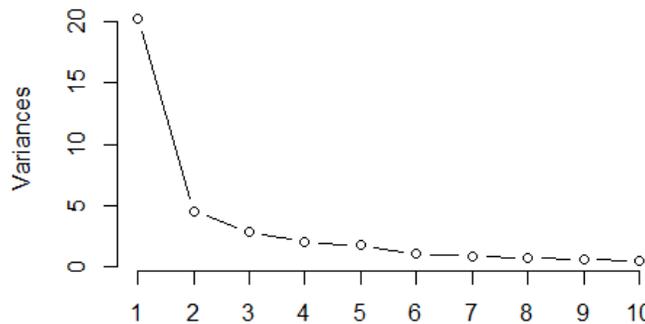


Figura 33. Curva de referencia del error, del parámetro pendientes.

En la Tabla 17 se muestran únicamente los valores correspondientes a las primeras seis componentes principales de las 11 variables para los tres parámetros (elevación, orientación y pendiente), por efectos de



extensión del documento. En la misma tabla se indica la varianza con mayor importancia, la cual está concentrada en los CP1 y CP2, para cada parámetro morfológico.

Para la comprobación de correlación de las variables principales con los componentes principales escogidos; CP1 Y CP2, se empleó la correlación lineal, y se obtiene los resultados de la Tabla 18.

Tabla 17. Valores de la varianza para cada CP.

Elevación	Desviación Estándar	Proporción de la Varianza	Proporción de la Varianza Acumulada
CP1	4,58	0,6	0,6
CP2	2,26	0,15	0,75
CP3	1,35	0,05	0,8
CP4	1,32	0,05	0,85
CP5	1,04	0,03	0,88
CP6	0,99	0,03	0,91

Pendiente	Desviación Estándar	Proporción de la Varianza	Proporción de la Varianza Acumulada
CP1	4,51	0,52	0,52
CP2	2,14	0,12	0,64
CP3	1,71	0,075	0,715
CP4	1,53	0,06	0,775
CP5	1,35	0,046	0,821
CP6	1,081	0,02	0,841

Orientación	Desviación Estándar	Proporción de la Varianza	Proporción de la Varianza Acumulada
CP1	2,9	0,22	0,22
CP2	2,61	0,18	0,4
CP3	2,17	0,125	0,525
CP4	1,73	0,07	0,595
CP5	1,38	0,05	0,645
CP6	1,33	0,04	0,685

Los valores de la Tabla 19 y



Por otra parte, la longitud de la mayor parte de los vectores es bastante uniforme a excepción de variables como la desviación estándar del amortiguador a 1000, relación entre área de la cuenca y el volumen del lago, volumen desarrollado, lo que indica poca relevancia dentro de los CP1 y CP2.

Las variables geométricas no produjeron mayores grados de explicación ni diferencias importantes en los parámetros de la correlación.

Con relación a la variable morfológica de la orientación o aspectos, las variables con mayor correspondencia indirecta son las relaciones del área de la cuenca, el área y volumen del lago, con la orientación con un amortiguamiento a 10, 50, 100, 200, 500 y 1000, pero que no son representativas ni influyentes para su predicción, como indica la **Figura 35** donde la longitud de estos vectores es pequeña.

Tabla 20 muestran las correlaciones entre las variables principales y solo las CP elegidas. Estas correlaciones encontradas, no fueron significativas y nada explicativas en las 11 variables estudiadas de los 145 lagos, tanto para las CP1 y CP2. De ahí que, la orientación, la altitud, ni la pendiente pudieren ser predictores del área, volumen o profundidad máxima.

De igual forma que en el parámetro de elevación, los CP seleccionados por la importancia de las varianzas fueron los CP1 y CP2, e indicando correlaciones inversas y que no son significativas.

La representación gráfica de las variables a través del Biplot se ilustra en la Figura 34, Figura 35 y Figura 36 para la altitud, orientación (aspecto) y pendiente, respectivamente. Para efectos de compresión del grafico se asignaron las siguientes abreviaturas a las diferentes variables: Longitud de Orilla = L_Ori, Volumen = Vol, Profundidad Máxima = P_max, Profundidad media = P_med, Profundidad relativa = P_rel, Volumen desarrollado = Vol_des, Área de la cuenca = Ac, relación entre Área de la cuenca y Área del Lago = Ac/AL, relación entre Área de la cuenca y Volumen Lago = Ac/VL.

Tabla 18. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro elevación.

Var. Morf.	Elevación	
	CP1	CP2
Área	-0,072	-0,358
Long, De Orilla	-0,065	-0,358
Volumen	-0,056	-0,356
Prof. máx.	-0,047	-0,402
Long. De Orilla (des)	-0,001	-0,202
Prof. media	-0,051	-0,395
Prof. relativa (índex)	-0,002	-0,273



Volumen (des)	-0,029	-0,123
Área cuenca/área lago	-0,063	0,124
Área cuenca/volumen lago	-0,008	0,133
Área de la cuenca	-0,140	-0,112
Hmax10	0,217	-0,040
Hmean10	0,217	-0,031
HSd10	0,215	0,016
Hmax20	0,216	-0,044
Hmean20	0,217	-0,032
HSd20	0,214	0,028
Hmax30	0,216	-0,047
Hmean30	0,217	-0,033
HSd30	0,212	0,038
Hmax50	0,216	-0,053
Hmean50	0,217	-0,035
HSd50	0,207	0,059
Hmax100	0,213	-0,069
Hmean100	0,217	-0,039
HSd100	0,182	0,106
Hmax200	0,206	-0,091
Hmean200	0,216	-0,047
HSd200	0,145	0,125
Hmax500	0,185	-0,127
Hmean500	0,213	-0,066
HSd500	0,108	0,110
Hmax1000	0,173	-0,109
Hmean1000	0,207	-0,085
HSd1000	0,040	-0,096

Las variables que se encuentran directamente relacionadas son las profundidades medias, máximas, relativas, longitud de la orilla, como primer grupo de relaciones. Como es lógico suponer las relaciones entre la altitud y sus diferentes medidas de amortiguamiento son altas, pero carecen de total significancia.



El área de la cuenca presenta una relación indirecta con las variables de la desviación estándar de la altitud 500, 200 y 100, pero con valores de significancia muy bajos. Al poseer un ángulo cerca de 90°, entre las variables geométricas y los diferentes amortiguadores de la altitud se explica una relación nula y no explicativa entre estas variables.

Tabla 19. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro orientación.

Variable morfométrica	Orientación	
	CP1	CP2
Área	-0,130	-0,097
Long. De Orilla	-0,154	-0,097
Volumen	-0,116	-0,085
Prof. máx.	-0,091	-0,108
Long, De Orilla (des)	-0,155	-0,036
Prof. media	-0,086	-0,112
Prof. relativa (índex)	0,023	-0,078
Volumen (des)	0,017	-0,058
Área cuenca/área lago	-0,056	0,079
Área cuenca/volumen lago	-0,071	0,058
Área de la cuenca	-0,100	-0,035
Apmax10	-0,126	-0,157
Apmean10	0,155	-0,252
ApSd10	-0,190	-0,166
Apmax20	-0,155	-0,151
Apmean20	0,167	-0,287
ApSd20	-0,234	-0,150
APmax30	-0,144	-0,113
Apmean30	0,168	-0,301
ApSd30	-0,259	-0,142



Apmax40	-0,141	-0,146
Apmean40	0,165	-0,306
ApSd40	-0,266	-0,125
Apmax50	-0,138	-0,167
Apmean50	0,165	-0,307
ApSd50	-0,271	-0,105
Apmax100	-0,148	-0,061
Apmean100	0,164	-0,290
ApSd100	-0,271	-0,067
Apmax200	-0,137	0,037
Apmean200	0,149	-0,276
ApSd200	-0,254	-0,052
Apmax500	-0,099	0,008
Apmean500	0,125	-0,254
ApSd500	-0,207	-0,044
Apmax1000	-0,110	-0,041
Apmean1000	0,092	-0,231
ApSd1000	-0,183	-0,050

Por otra parte, la longitud de la mayor parte de los vectores es bastante uniforme a excepción de variables como la desviación estándar del amortiguador a 1000, relación entre área de la cuenca y el volumen del lago, volumen desarrollado, lo que indica poca relevancia dentro de los CP1 y CP2.

Las variables geométricas no produjeron mayores grados de explicación ni diferencias importantes en los parámetros de la correlación.

Con relación a la variable morfológica de la orientación o aspectos, las variables con mayor correspondencia indirecta son las relaciones del área de la cuenca, el área y volumen del lago, con la orientación con un amortiguamiento a 10, 50, 100, 200, 500 y 1000, pero que no son representativas ni influyentes para su predicción, como indica la **Figura 35** donde la longitud de estos vectores es pequeña.

Tabla 20. Correlación entre variables, para las componentes CP1 y CP2, para el parámetro Pendiente.

Var. Morf.	Pendiente	
	CP1	CP2
Área	-0,089	-0,313
Long. De Orilla	-0,096	-0,318
Volumen	-0,086	-0,281



Prof. máx.	-0,137	-0,264
Long. De Orilla (des)	-0,060	-0,159
Prof. media	-0,137	-0,242
Prof. relativa (índex)	-0,136	-0,092
Volumen (des)	-0,056	-0,012
Área cuenca/área lago	0,025	0,085
Área cuenca/volumen lago	0,052	0,036
Área de la cuenca	-0,059	-0,117
Smax10	-0,192	-0,136
Smean10	-0,186	-0,078
Sd10	-0,197	-0,098
Smax20	-0,196	-0,118
Smean20	-0,200	-0,019
Sd20	-0,202	-0,072
Smax30	-0,199	-0,102
Smean30	-0,202	0,018
Sd30	-0,205	-0,046
Smax40	-0,201	-0,081
Smean40	-0,202	0,046
Sd40	-0,205	-0,022
Smax50	-0,199	-0,066
Smean50	-0,201	0,065
Sd50	-0,205	-0,001
Smax100	-0,192	0,041
Smean100	-0,193	0,133
Sd100	-0,196	0,110
Smax200	-0,181	0,100
Smean200	-0,176	0,195
Sd200	-0,178	0,198
Smax500	-0,128	0,189
Smean500	-0,149	0,236
Sd500	-0,140	0,257
Smax1000	-0,117	0,209
Smean1000	-0,130	0,250
Sd1000	-0,111	0,268



Por último, los amortiguamientos de las pendientes no tienen relación con las variable morfo-métricas y poseen importancia significativa para su predicción. Las tres anteriores figuras muestran que los lagos/observaciones, no poseen un valor promedio de las pendientes para ningún amortiguamiento, esto concuerda con el relieve irregular del PNC.

Las variables de profundidad máxima media, volumen y longitud de orilla están relacionadas indirectamente con la altitud y las relaciones entre área de la cuenca y el área y volumen del lago, pero que no son significativas ni explicativas.

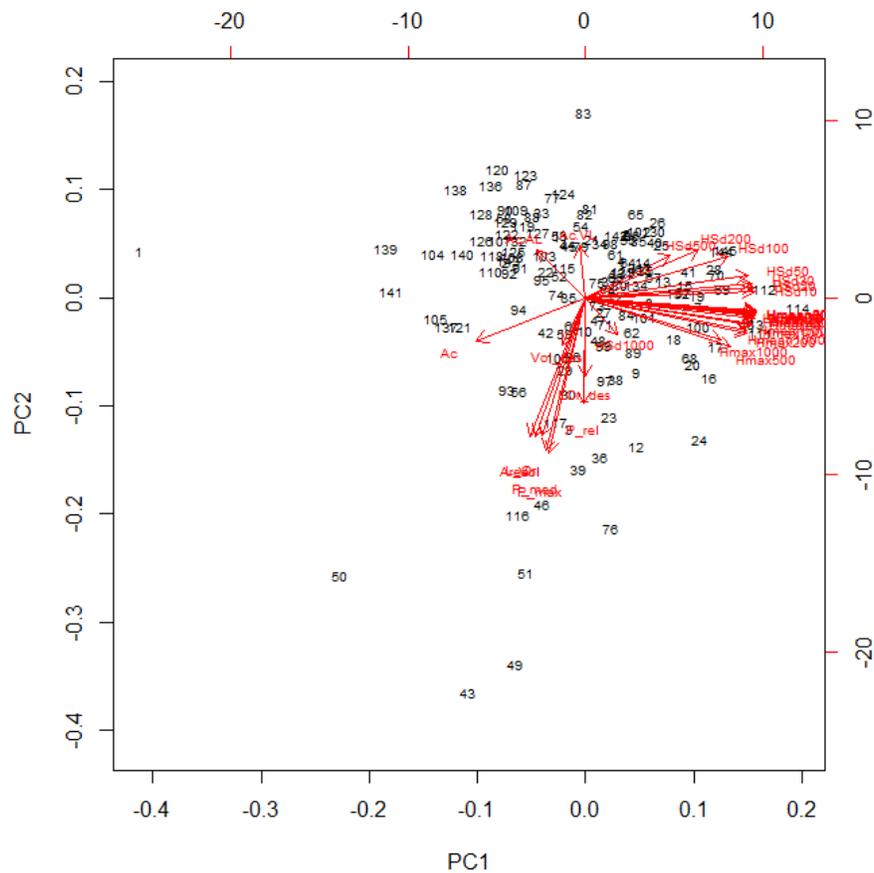


Figura 34. PCA de las variables morfológicas con respecto a la Altitud.

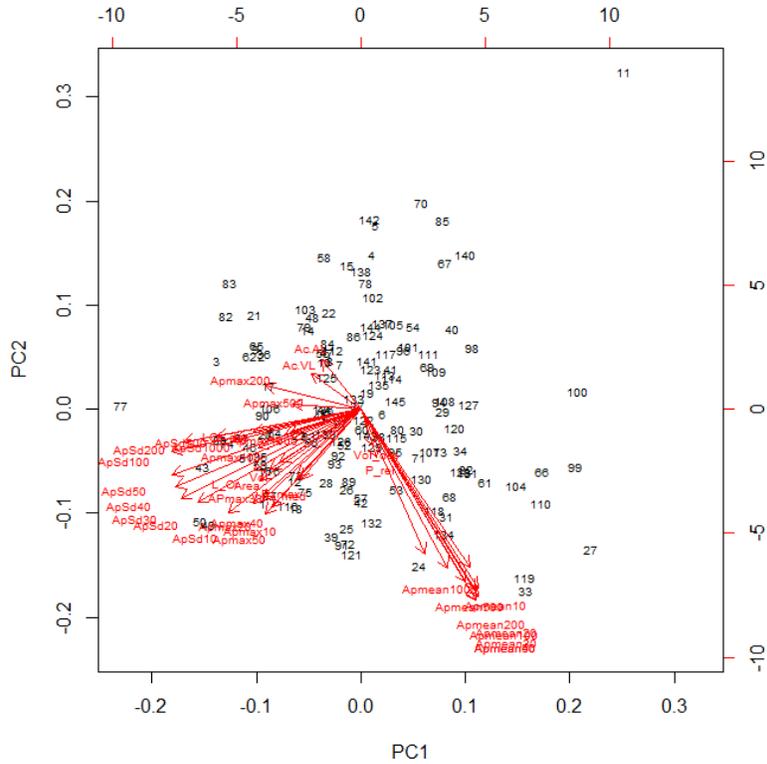


Figura 35. PCA de las variables morfológicas con respecto al aspecto del alrededor de los lagos.

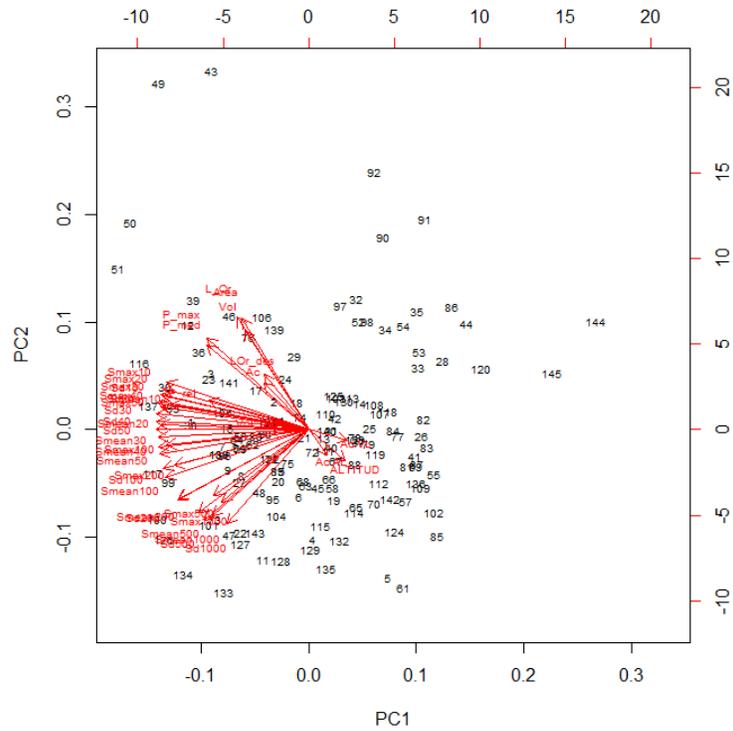


Figura 36. PCA de las variables morfológicas con respecto a la pendiente del alrededor de los lagos



4 CAPITULO IV: DISCUSIÓN

4.1 Mapa de uso/cobertura del suelo del Macizo del Cajas (MzC)

Los errores resultantes de las clasificaciones están relacionados con las similitudes entre las firmas espectrales (vías y área urbana, ríos y matorrales), los mismos que se corrigieron con los modelos de cobertura disponibles. En lo que respecta a las categorías de uso del suelo, se puede observar que existen diferencias de precisión a nivel de clases en los diferentes métodos, para la zona urbana, suelo descubierto y los cuerpos de agua. Así, la baja precisión, para cuerpos de agua, de alrededor de 0,7, sugiere que algunas áreas fueron omitidas de esta clase e incluidas en otra (p. ej., manglares). Esto debido a que el espectro de firmas es muy similar con lechos de ríos y áreas antrópicas. Adicionalmente, es muy factible que cierta turbidez existente en los lagos por los sedimentos haya disminuido la calidad de reflectividad y, consecuentemente, la correcta clasificación de pixeles (Córdoba *et al.*, 2006).

El comportamiento del algoritmo paramétrico MV y por su lado ANN mostraron óptimos resultados, con una ligera mejora para el primero. Con respecto a la precisión global, ANN mostro mejores resultados, esto debido al método de algoritmo de aprendizaje de retro propagación y al tamaño de la red neuronal.

4.2 Estima de la profundidad de los lagos y lagunas del PNC

Los resultados del algoritmo para estimar la profundidad de lagos sugieren una creciente dificultad para discriminar profundidades mayores a los 25 m, es decir a mayores profundidades las diferencias de las señales registradas por el sensor cuando son muy pequeñas representan diferencias de profundidad de agua relativamente grandes. Esto concuerda con investigaciones anteriores en el sentido de que las relaciones lineales consideradas en este tipo de algoritmos no es válida para lagos profundos donde el efecto del fondo del lago es nulo (Stumpf *et al.*, 2003).

A pesar de los buenos ajustes que presentó el modelo de banda roja, se optó por revisar su capacidad predictiva mediante los errores individuales de cada predicción, de tal modo que se pueda estimar las profundidades con el menor error posible. En este mismo contexto, el mejor desempeño de la banda roja se debe posiblemente a las propiedades de la banda para distinguir la reflectancia y transmitancia reflejada por materiales en suspensión (Campbell and Wynne, 2011).

(Stumpf *et al.*, 2003) encontraron que utilizando longitudes de onda de 0,50 – 0,60 μm era posible mapear profundidades de hasta 20 m, lo que coincide con los presentes resultados, ya que el coeficiente de absorción del



agua aumenta exponencialmente en la parte roja del espectro y a pequeños cambios en la profundidad del agua tienen un impacto significativo en la señal de salida del agua.

Con base en el análisis de las profundidades medidas en campo y las estimadas por el modelo, se observó que en el rango de profundidad que va de 0 m a 3 m, el error en la estima alcanzó valores inferiores a 1,5 m. Al contrario, para profundidades mayores a 10 m, las diferencias se hacen más evidentes. Sin embargo, la absorción de luz por el agua es tan fuerte que no hay un efecto de fondo en la reflectancia si el agua es más profunda que 5 m. De ahí la baja capacidad predictiva demostrada por el algoritmo ($r = 0,22$) que se ve afectado por la potencial presencia de material en suspensión sólido (inorgánico) en la columna de agua (Mosquera et al., 2017), respaldado por el hecho de que se observó el efecto de corrimiento en el espectro del pico de máxima reflectancia; además se percibió un aumento considerable de la reflectancia de la banda azul, sugiriendo la presencia de material orgánico (fito-plancton) y/o sólidos en suspensión.

La turbidez de los cuerpos de agua con concentraciones mayores a 5 mg L^{-1} y profundidades hasta de 0,30 m, hace que la reflectancia de agua sea debida principalmente a ella misma y no a las características del fondo, lo cual quiere decir que hay muy poca penetración de la energía (Bartolucci and Robinson, 1977). En este sentido (Van Colen *et al.*, 2017) sugieren concentraciones de sólidos suspendidos en los cuerpos de agua estudiados en los lagos del PNC mayores a $3,8 \text{ mg L}^{-1}$, lo cual es significativamente alto para lograr una mejor performance del modelo ensayado.

Sin embargo, en esta investigación no se contó con información sobre constituyentes ópticamente activos es decir concentraciones de fitoplancton, material suspendido y sustancias amarillas, para la fecha de adquisición de la imagen satelital. Por otra parte, la variabilidad de las profundidades se ve afectada por la presencia de aerosoles continentales, la reflectancia del fondo y la adyacencia de la tierra. La corrección de estos efectos requiere del conocimiento del aerosol regional y las propiedades ópticas del fondo (Hoepffner and Zibordi, 2009).

Una de las limitaciones presentes en este estudio fue el no disponer de datos concurrentes entre las fechas de adquisición de la imagen y los datos de campo, ya que no se puede desarrollar un modelo predictivo preciso realista, por la cantidad considerable de errores asociados las condiciones atmosféricas o del lago (McCullough *et al.*, 2012).

4.3 Análisis de la potencial correlación entre variables limnimétricas de los lagos y lagunas del PNC



y las propiedades morfológicas de los alrededores de estos lagos y lagunas

El presente análisis muestra que ni el área, ni la profundidad ni el volumen del lago se pueden modelar a partir de parámetros físicos derivados del contorno de los cuerpos de agua. El grado de explicación fue muy bajo para todas las variables. También mostró que, el contar con amortiguamientos (“buffers”) de varios anchos no aumentó significativamente el dominio predictivo del modelo. Como resultado, las predicciones de la profundidad del lago a partir de los parámetros físicos del contorno de los lagos son tan inciertas que esencialmente carecen de significado, tanto para lagos profundos como para someros.

Estos resultados contrastan, con los obtenidos por (Rowan *et al.*, 2006) quienes pudieron modelar la profundidad a partir de datos derivados de los parámetros físicos de los contornos de los lagos de alta montaña. Esta diferencia en relación al presente estudio podría deberse, por ejemplo, a que no se pudieron analizar parámetros más geomorfológicos tales como distribución de unidades de suelos, distribución de unidades geológicas o tasas potenciales de erosión (p. ej., aplicando el método RUSLE). Este es un análisis que debería llevarse a cabo en el futuro.

Se intentaron además varias formas de aumentar el nivel de significancia de las relaciones entre las variables limnológicas y las físicas de los contornos de los lagos, tales como dividir todo el conjunto de datos en regiones geográficas o en diferentes clases de acuerdo al tamaño de los lagos, etc., pero todo ello no aumentó el poder predictivo. En este sentido, se procuró encontrar agrupaciones similares en los datos, pero ni la agrupación jerárquica, ni la agrupación por eliminación de variable con mínima significancia lograron aumentar el desempeño de la estadística del ACP.



5 CONCLUSIONES

5.1 Generación de un mapa de uso/cobertura del suelo en el Macizo del Cajas (MzC)

La variabilidad, que por lo general está relacionada a la siembra y al cambio de uso de suelo, no es una constante definitoria en este estudio debido a que la mayor parte de la biosfera se encuentra protegida, lo que hace posible un análisis multi-temporal.

Por otro lado, un algoritmo que produzca una imagen con un porcentaje de clasificación correcta que supere el 90% es considerado bueno. Este trabajo obtuvo la clasificación del uso/cobertura del suelo, produciendo un mapa temático del uso/cobertura del suelo en el Macizo del Cajas (MzC), integrando imágenes satelitales con datos auxiliares derivados de modelos de cobertura terrestre actualmente disponibles. Para la clasificación se utilizaron datos digitales de Lansat 8 OLI, y se compararon tres métodos de clasificación supervisada por pixel.

Las firmas espectrales relacionadas de algunos elementos generaron confusiones entre las clases de cobertura del suelo (p. ej., cauces de ríos y matorrales). Se utilizaron datos auxiliares para reducir los errores y discriminar entre categorías que resultaron difíciles de clasificar. Se aplicaron el clasificador de máxima verosimilitud (MV) y el de la distancia de Mahalanobis (MH) que representan métodos de clasificación convencional, y un clasificador de Redes Neuronales Artificiales (ANN) que representa algoritmos de clasificación supervisada.

El mejor método en términos de precisión de clasificación general (previo a la aplicación de filtros de suavizado) fue ANN, con una precisión de alrededor de 1,3. El segundo mejor método fue MV con una precisión de clasificación general de 2,7 seguido finalmente por MH con una precisión de 5,9. De igual forma, la aplicación de filtros de reducción de ruido y suavizado mejoraron aún más el rendimiento del algoritmo ANN.

El algoritmo de ANN aplicado a la clasificación de uso/cobertura de suelos, ofrece mucho potencial, en particular, la capacidad de estimar las capas de salida de manera iterativa, para lograr el error mínimo objetivo es meritorio. En lo que respecta al tiempo de procesamiento, el método de ANN tomó mucho más tiempo que los otros dos métodos.

Por último, se concluye que el MzC posee un área promedio de conservación y protección del 38,8% del área total. El uso para actividades productivas humanas representa el 33,2% del territorio y el uso antrópico adicional el 0,3%. El manglar representa el 1,16% del territorio, mientras que los lagos y lagunas representan un 3,0% del área total.



5.2 Estima de la profundidad de los lagos y lagunas del PNC

En lo que se refiere a la estimación de la profundidad de lagos, el modelo utilizado obtuvo mayor precisión en las zonas con mayor transparencia (profundidades intermedias de 2 a 4 m), mientras que en zonas de aguas turbias se presentó una sobrestimación de la profundidad. Por consiguiente, la banda roja es la mejor para cartografiar la profundidad en aguas de menos de 5 m de profundidad, pero no puede utilizarse para estimar la profundidad de aguas más profundas.

De acuerdo con los resultados obtenidos, existe una muy baja correlación espacial entre las profundidades estimadas y observadas, con una subestimación en el orden del 20% al 40% de la profundidad promedio de los lagos. Esta baja exactitud tendría su explicación en el efecto del fondo de los lagos (lagos someros) y la influencia de los sedimentos en suspensión en la degradación de la reflectancia. El método utilizado en esta investigación, de una sola banda (SBA), supone que el coeficiente de atenuación es constante lo cual hace que se omita varias características del tipo de fondo.

A pesar de ello, el algoritmo aplicado es capaz de distinguir entre lagos someros o profundos, lo cual ya es un resultado bastante significativo para la gestión de los lagos y lagunas del MzC, si se considera que el método ensayado podría aplicarse en el futuro en imágenes de sensores remotos colectadas a largo plazo y en áreas extensas.

No obstante, se recomienda que se realicen pruebas futuras a través de otros algoritmos que aislen los cambios de profundidad por las inferencias de otros componentes.

5.3 Análisis de la potencial correlación entre variables limnimétricas de los lagos y lagunas del PNC y las propiedades morfológicas de los alrededores de estos lagos y lagunas.

Este trabajo presenta el análisis estadístico de una base de datos de 145 lagos en el PNC. El objetivo básico fue el de inspeccionar si existen relaciones estadísticas entre las variables limnimétricas de los lagos y los parámetros físicos (particularmente morfológicos) de los alrededores de los lagos (calculadas empleando buffers de diverso ancho), para así estimar parámetros tales como la profundidad, el área o el volumen. Sin embargo, los resultados del análisis estadístico por Componentes Principales (CP) no mostraron un buen desempeño cuando se estudió las posibles relaciones entre la profundidad máxima de los lagos y la altitud, la orientación (aspecto) y la pendiente.

En este sentido, es recomendable expandir en el futuro el presente análisis, integrando al mismo, variables más geomorfológicas, tales como distribución de suelos y de unidades geológicas, estimas de erosión potencial, etc.



6 REFERENCIAS

- Aguilar Arias, H., Mora Zamora, R. and Vargas Bolaños, C. 2014. Metodología Para La Corrección Atmosférica De Imágenes Aster, Rapideye, Spot 2 Y Landsat 8 Con El Módulo Flaash Del Software Envi. *Revista Geográfica de América Central* 53: 39–59.
- Almanza Marroquin, V., Figueroa, R., Parra, O., Fernandez, X., Baeza, C., Yanez, J. and Urrutia, R. 2016. Bases limnológicas para la gestión de los lagos urbanos de Concepción, Chile. *Latin American Journal of Aquatic Research* 44: 313–326.
- Aziz, N., Minallah, N., Junaid, A. and Gul, K. 2017. Performance Analysis of Artificial Neural Network Based Land Cover Classification. 11: 422–426.
- Bartolucci, L.A. and Robinson, B.F. 1977. Field measurements of the spectral response of natural waters. *Photogrammetric Engineering and Remote Sensing* 43: 595–598.
- Bertona, L.F. 2005. [Entrenamiento de redes neuronales basado en algoritmos evolutivos.
- Buytaert, W., Iñiguez, V. and Bièvre, B. De 2007. The effects of afforestation and cultivation on water yield in the Andean páramo. *Forest Ecology and Management* 251: 22–30.
- Buytaert, W., Célleri, R., De Bièvre, B. and Cisneros, F. 2009. Hidrología del Páramo Andino: Propiedades, Importancia y Vulnerabilidad. .
- Campbell, J.B. and Wynne, R.H. 2011. *Introduction to Remote Sensing*, 5th ed. Guilford Press, New York, .
- Castillo Jurado, M. del, Armengol, J. and Ferrer i Parareda, X. 2004. *Morfometría de lagos una aplicación a los lagos del Pirineo*. Universitat de Barcelona, Barcelona, .
- Ceyhun, Ö. and Yalçın, A. 2010. Remote sensing of water depths in shallow waters via artificial neural networks. *Estuarine, Coastal and Shelf Science* 89: 89–96.
- Chuvieco, E. 2008. *Teledetección Ambiental: La Observación de La Tierra Desde El Espacio*. Ariel, .
- Van Colen, W.R., Mosquera, P., Vanderstukken, M., Goiris, K., Carrasco, M.C., Decaestecker, E., Alonso, M., León-Tamariz, F. and Muylaert, K. 2017. Limnology and trophic status of glacial lakes in the tropical Andes (Cajas National Park, Ecuador). *Freshwater Biology* 62: 458–473.
- Córdoba, E., Puentes, M. and Otero, L. 2006. Análisis de imágenes Landsat-7 ETM+ para determinar la cobertura del suelo de la zona costera de la bahía de Tumaco. *Boletín Científico CCCP* 41–52.
- Dong, J., Zhuang, D., Huang, Y. and Fu, J. 2009. Advances in multi-sensor data fusion: Algorithms and applications. *Sensors* 9: 7771–7784.
- Du, C.J. and Sun, D.W. 2004. Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science and Technology* 15: 230–249.
- Duarte, D.C., Zanetti, J., Gripp Junior, J. and Medeiros, N. 2018. Comparison of supervised classification methods of Maximum Likelihood, Minimum Distance, Parallelepiped and Neural Network in images of Unmanned Air Vehicle (UAV) in Viçosa - MG. *Revista Brasileira de*



Cartografía 70: 437–452.

- Dukatz, F., Ferrati, R. and Canziani, G. 2006. Clasificación de lagos someros pampeanos mediante imágenes Landsat TM. *Biología Acuática*.
- Ellah, A.R.A., Essai, M.H. and Yahya, A. 2015. Comparison of different backpropagation training algorithms using robust M-estimators performance functions. *In 2015 Tenth International Conference on Computer Engineering & Systems (ICCES)* 384–388.
- ETAPA 2013. Programa: Manejo Integrado de cuencas para la Protección de Fuentes de Agua. *MICPA* 75.
- ETAPA EP 2018. ACTUALIZACIÓN DEL PLAN DE MANEJO DEL PARQUE NACIONAL CAJAS.
- Felicísimo, A.M. and Cuartero, A. 2009. Clasificación de imágenes multiespectrales ASTER mediante funciones adaptativas. .
- Figueiredo, I.N., Pinto, L. and Gonçalves, G. 2016. A Modified Lyzenga ' s Model for Multispectral Bathymetry Using Tikhonov Regularization. 13: 53–57.
- Fonstad, M.A. and Marcus, W.A. 2005. Remote sensing of stream depths with hydraulically assisted bathymetry (HAB) models. 72: 320–339.
- Freeman, J.A. and García-Bermejo, R. 1993. *Redes Neuronales : Algoritmos, Aplicaciones Y Técnicas de Programación*. Addison-Wesley, .
- Frinelle, B.G. and Moody, A. 2001. Mapping Continuous Distributions of Land Cover : A Comparison of Maximum-Likelihood Estimation and Artificial Neural Networks. 67: 693–705.
- Gandía Franco, S. and Meliá Miralles, J. 1991. *La Teledetección En El Seguimiento de Los Fenómenos Naturales : Recursos Renovables, Agricultura*. Universidad de Valencia, .
- Gholamalifard, M., Kutser, T., Esmaili-Sari, A., Abkar, A.A. and Naimi, B. 2013. Remotely sensed empirical modeling of bathymetry in the southeastern Caspian Sea. *Remote Sensing* 5: 2746–2762.
- Grossman, G.D., Nickerson, D.M., Freeman, M.C. and Feb, N. 2007. Principal Component Analyses of Assemblage Structure Data : Utility of Tests Based on Eigenvalues PRINCIPAL COMPONENT ANALYSES OF ASSEMBLAGE STRUCTURE DATA: UTILITY OF TESTS BASED ON EIGENVALUES1. *Journal of Mammalogy* 72: 341–347.
- Hidropaute 2009. Hidropaute Informe de Gestión 2009. .
- Hoepffner, N. and Zibordi, G. 2009. Remote Sensing of Coastal Waters. *Encyclopedia of Ocean Sciences* 732–741.
- Hogland, J., Billor, N. and Anderson, N. 2013. Comparison of standard maximum likelihood classification and polytomous logistic regression used in remote sensing. *European Journal of Remote Sensing* 46: 623–640.
- Hubbard, R. and Allen, S.J. 1987. An empirical comparison of alternative methods for principal



- component extraction. *Journal of Business Research* 15: 173–190.
- Jagalingam, P., Akshaya, B.J. and Hegde, A.V. 2015. Bathymetry mapping using landsat 8 satellite imagery. *Procedia Engineering* 116: 560–566.
- Jolliffe, I.T. 1973. Discarding Variables in a Principal Component Analysis. I: Artificial Data. *Journal of the Royal Statistical Society Ser: 21: 21–31.*
- Josse, C., Navarro, G., Comer, P.J., Evans, R. and Faber, D. 2003. ECOLOGICAL SYSTEMS OF LATIN AMERICA AND THE CARIBBEAN A WORKING CLASSIFICATION OF TERRESTRIAL SYSTEMS. .
- Kavzoglu, T. and Mather, P.M. 2003. The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing* 24: 4907–4938.
- Kessler, M. 2006. Bosques de Polylepis. .
- Kruse, F.A. 2004. Comparison of ATREM, ACORN, and FLAASH atmospheric corrections using low-altitude AVIRIS data of Boulder, CO. *In Summaries of 13th JPL Airborne Geoscience Workshop.*
- Kulicz, A. 1965. Przypadek gruczolako-mie??niakowato??ci pecherzyka z????ciowego (adenomyomatosis). *Polski Przegląd Radiologii I Medycyny Nuklearnej* 29: 301–305.
- Lakewatch, F. 2001. A Beginner ' s Guide to Water Management — Lake Morphometry. *Aquatic Sciences.*
- Leu, L.G. and Chang, H.W. 2005. Remotely sensing in detecting the water depths and bed load of shallow waters and their changes. *Ocean Engineering* 32: 1174–1198.
- Liang, S., Fang, H. and Chen, M. 2001. Atmospheric correction of Landsat ETM+ land surface imagery- Part I: Methods. *IEEE Transactions on Geoscience and Remote Sensing* 39: 2490–2498.
- Louchard, E.M., Reid, R.P., Stephens, F.C., Davis, C.O., Leathers, R.A. and Downes, T.V. 2003. Optical remote sensing of benthic habitats and bathymetry in coastal environments at Lee Stocking Island , Bahamas : A comparative spectral classification approach. 48: 511–521.
- Lyzenga, D.R. 1978. Passive remote sensing techniques for mapping water depth and bottom features. *Applied Optics* 17: 379–383.
- Lyzenga, D.R. 1981. Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and Landsat data. *International Journal of Remote Sensing* 2: 71–82.
- Lyzenga, D.R. 1985. Shallow-water bathymetry using combined lidar and passive multispectral scanner data. *International Journal of Remote Sensing* 6: 115–125.
- Mahalanobis, P.C. 1936. On the generalized distance in statistics In: Proceedings of the National Institute of Science, India. .
- McCullough, I.M., Loftin, C.S. and Sader, S.A. 2012. Combining lake and watershed characteristics with Landsat TM data for remote estimation of regional lake clarity. *Remote Sensing of Environment* 123: 109–115.



- Meyer, P., Itten, K.I., Kellenberger, T., Sandmeier, S., Sandmeier, R. and Laboratories, R.S. 2003. Applicability of landsat tm data for inventorying and monitoring of frubber. .
- Montgomery, D.C. 2011. *Applied Statistics and Probability for Engineer*, 5th ed.
- Mosquera, P. V., Hampel, H., Vázquez, R.F., Alonso, M. and Catalan, J. 2017. Abundance and morphometry changes across the high-mountain lake-size gradient in the tropical Andes of Southern Ecuador: TROPICAL ANDES LAKE-SIZE GRADIENT. *Water Resources Research* 53: 7269–7280.
- Ormeño, S. 2006. Teledetección fundamental. 344.
- Paola, J.D. and Schowengerdt, R.A. 1995. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. *IEEE Transactions on Geoscience and Remote Sensing* 33: 981–996.
- Parra, O., Valdovinos, C., Urrutia, R., Cisternas, M., Habit, E. and Mardones, M. 2003. Caracterización y tendencias tróficas de cinco lagos costeros de Chile Central. *Limnetica* 22: 51–83.
- Pérez, H.Á., Ibañez, S.G. and Rosas-acevedo, J.L. 2015. Análisis de componentes principales en un ecosistema léntico de México. .
- Quirós, R. 2004. Sobre la morfología de las lagunas pampeanas. *Documento de Trabajo Del Área de Sistemas de Producción Acuática N° 33*: 1–15.
- Rejas Ayuga, J.G. 2008. [*Tratamiento Digital Previo de las Imágenes*].
- Riaño, D., Salas, J. and Chuvieco, E. 2000. Corrección Atmosférica y Topográfica , Información Multitemporal y Auxiliar Aplicadas a la Cartografía de Modelos de Combustibles con Imágenes Landsat-TM. *Tecnologías Geográficas Para El Desarrollo Sostenible: IX Congreso Del Grupo de Métodos Cuantitativos, Sistemas de Información Geográfica Y Teledetección 2000*: 222–239.
- Richards, J.A. and Jia, X. 2006. Supervised Classification Techniques. In: *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin/Heidelberg, pp. 193–247.
- Rodríguez Girón, S., Rodas López, F., Schubert, A. and Vasco Tapia, S. 2015. *Área de Biosfera Macizo Del Cajas-Experiencias de Desarrollo Sostenible Para El Buen Vivir (Cajas Massif Biosphere Area-Sustainable Development Experiences for Good Living)(2da Ed.)*. Cuenca, Ecuador: ETAPA EP, Con El Aval de UNESCO Y El Comité Promotor Pa.
- Rowan, J.S., Soutar, I. and Phillips, G.E. 2006. Morphometric analysis of UK lake systems as a compliance tool for the European Water Framework Directive. *Sediment Dynamics and the Hydromorphology of Fluvial Systems* 306: 257–266.
- Secretaría de la Convención de Ramsar 2013. Manual de la Convención de Ramsar: Guía a la convención sobre los Humedales (Ramsar, Irán, 1971). *6ta. Edición. Secretaría de La Convención de Ramsar, Gland.(Suiza)*.
- Sierra, R. 1999. *Propuesta Preliminar de Un Sistema de Clasificación de Vegetación Para El Ecuador Continental*. Proyecto INEFAN/GEF y EcoCiencia, .



- SIGMUR 2006. Páginas de SIG y Teledetección. *SIG y Teledetección en la Univ. Murcia*.
- Silvan-Cardenas, J.L. 2004. Optimal design of neural networks for land-cover classification from multispectral imagery. *Image and Signal Processing for Remote Sensing Ix* 5238: 420–431.
- Simone, G., Farina, A., Morabito, F.C., Serpico, S.B. and Bruzzone, L. 2002. Image fusion techniques for remote sensing applications. *Information Fusion* 3: 3–15.
- SIPA 2016. Mapa de cobertura y uso de la tierra. *Sistema de Información Pública Agropecuaria*.
- Stumpf, R.P. and Holderied, K. 2003. Determination of water depth with high-resolution satellite imagery over variable bottom types. *Limnology and Oceanography* 48: 547–556.
- Stumpf, R.P., Holderied, K. and Sinclair, M. 2003. Determination of water depth with high-resolution satellite imagery over variable bottom types. *Limnology and Oceanography* 48: 547–556.
- Tan, K.C., Lim, H.S. and Jafri, M.Z.M. 2011. Comparison of Neural Network and Maximum Likelihood Classifiers for Land Cover Classification Using Landsat Multispectral Data. 241–244.
- Tso, B. and Mather, P.M. 2009. *Classification Methods for Remotely Sensed Data*. CRC Press, .
- Uzcátegui, C., Solano, J. and Figueroa, P. 2016. Perspectiva sobre la sostenibilidad de los recursos naturales a largo plazo caso industria camaronera ecuatoriana. *Universidad Y Sociedad [Seriada En Línea]* 8: 163–168.
- Vega, J.C., Hoyos, C. De, Aldasoro Martín, J.J., Miguel, J. De and Fraile, H. 2005. Nuevos datos morfométricos para el Lago de Sanabria. *Limnética* 24: 115–121.
- Willington, E., Nolasco, M. and Bocco, M. 2013. Clasificación supervisada de suelos de uso agrícola en la zona central de Córdoba (Argentina): comparación de distintos algoritmos sobre imágenes Landsat. *Congreso Argentino de AgroInformática, CAI 2013* 207–216.
- Yuan, H., Van Der Wiele, C.F. and Khorram, S. 2009. An automated artificial neural network system for land use/land cover classification from landsat TM imagery. *Remote Sensing* 1: 243–265.
2010. Incorporation of aquatic ecology to the hydrological investigation of ecosystems in the high Andes. *Maskana* 1.

7 ANEXOS

ANEXO N°1



Información remota disponible para el estudio de profundidades de lagos y análisis de correlaciones entre variables limnológicas y morfo-métricas de lagos y lagunas en el PNC

Denominación	Nombre del Lago	Denominación	Nombre del Lago	Denominación	Nombre del Lago
1	Llaviucu	50	Mamamag / Taitachugo	97	Jigeno
2	Patoquinas	51	Sunincocha Grande	98	De Patos
3	Toreadora	52	Burín Grande	99	De la Cascada
4	Illincocha	53	Burín Chico 1	100	Cardenillo
5	Chica Toreadora	54	Burín Chico 2	101	Derrumbo Amarillo
6	Piñancocha	55	El Ocho	102	Perro Grande
7	Fondococha	56	3ra de Sunincocha	103	Chica Ventanas
8	Pallacocha	57	Las Chorreras	104	Bejuco
9	Riñoncocha	58	2da de Sunincocha	105	Tintacocha
10	Toreador	59	Quinuascocha	106	Ventanas
11	Ataudcocha	60	Potro muerto	107	Chusalongo 1
12	Tintacocha	61	Culebrillas	108	Chusalongo 2
13	Del Diablo	62	Cueva Escrita	109	Chusalongo 3
14	Contrahierba	63	Llipus loma	110	Chusalongo 4
15	Totorilla	64	Llipus loma 3	111	Del Sharo
16	Cristales	65	Llipus loma 2	112	Negra
17	Yanacocha de Jerez	66	Negra	113	De Patos Blancos
18	Yantahuaico 1	67	Azul	114	Juan Pasana
19	Yantahuaico 2	68	Pampeada Grande	115	Chica Hunanchi
20	Yantahuaico 3	69	Pampeada Chica	116	Hunanchi
21	Marmolcocha	70	Del Rayo	117	Verdes
22	Unidas	71	Cuchichaspana	118	Estrellascocha 2
23	Atugyacu Grande	72	Cuchichaspana Chica	119	Estrellascocha 3
24	Estrellascocha	73	Piedra Blanca o Llaviucu	120	Estrellascocha 4
25	Negra de Jerez	74	Ojo de Osohuaico	121	Dos Choreras
26	Atascaderos	75	Patos Colorados	122	Taquiurco
27	Pailacocha de Jerez	76	Lagartococha	123	Barros
28	Atugloma	77	Anexo Osohuayco	124	Barros 2
29	Angas	78	Ingacocha 2	125	Totoras
30	Dublaycocha	79	J	126	Verdecocha
31	S/N	80	Martillo	127	San Antonio 1

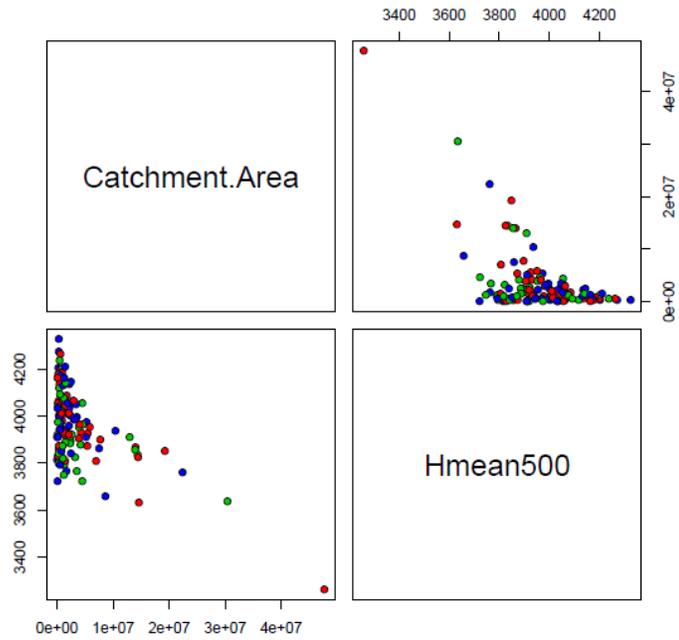


32	Estrellascocha	81	Apicocha 1	128	San Antonio 2
33	Lagunaloma o Verdecocha	82	Apicocha 2	129	Patococha grande 1
34	Napalé Vía	83	Apicocha 3	130	Cocha Jerez 3
35	Tinguercocha 1	84	Cascarilla 1	131	Lago Azul
36	Ingacasa	85	Cascarilla 2	132	Las Chorreras 2
37	Ingacocha 1	86	Cascarilla 3	133	Mangacocha 1
38	Chachacomos	87	Chica luspa 1	134	Mangacocha 2
39	Larga	88	Chica luspa 2	135	Mangacocha 3
40	Negra	89	Trensillas	136	Ira de Sunincocha
41	Cardenillo	90	Chullacocha	137	Hato de Chocar
42	Togllacocha	91	Quimsacocha 1	138	Lago somero Hato de Chocar 1
43	Luspa	92	Quimsacocha 2	139	Totoracocha
44	Tinguercocha 2	93	Vado de los Arrieros 1	140	Hato de chocar 2 o Tintacocha
45	Cucheros	94	Vado de los Arrieros 2	141	Chuspihuaycu
46	Canutillos Grande	95	Botacocha	142	Perro chico
47	Canutillos chica 2	96	Carpahuayco	143	Chico Juan Manuel
48	Canutillos chica 1	96	Carpahuayco	144	Atucpamba 1
49	Osohuayco	95	Botacocha	145	Atucpamba 3
		96	Carpahuayco		

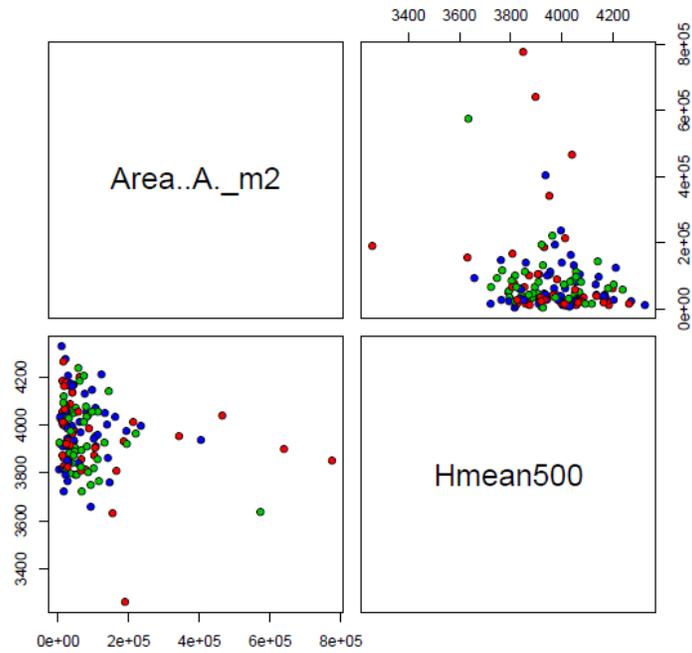
ANEXO 3. Resultados de las 11 variables limnológicas analizadas frente a los parámetros morfológicos de los lagos y lagunas



Variables de los Lagos

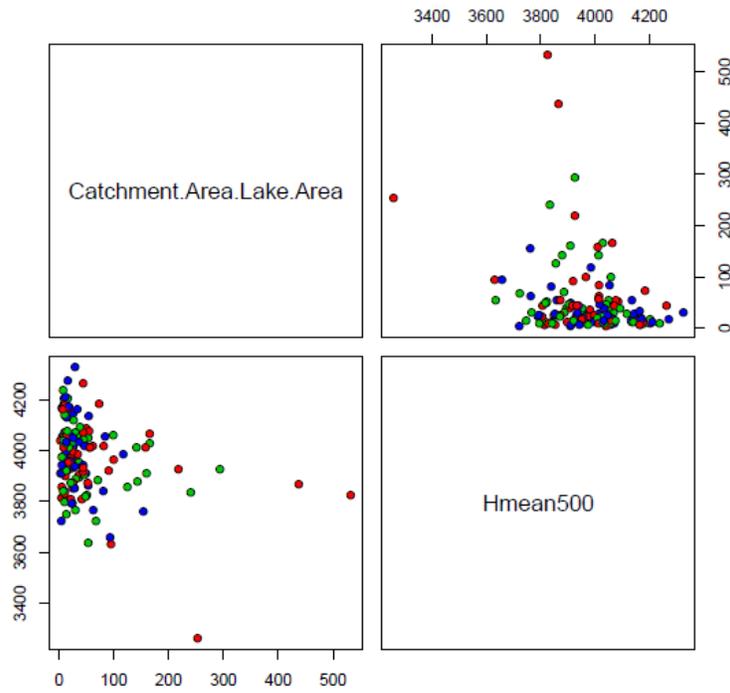


Variables de los Lagos

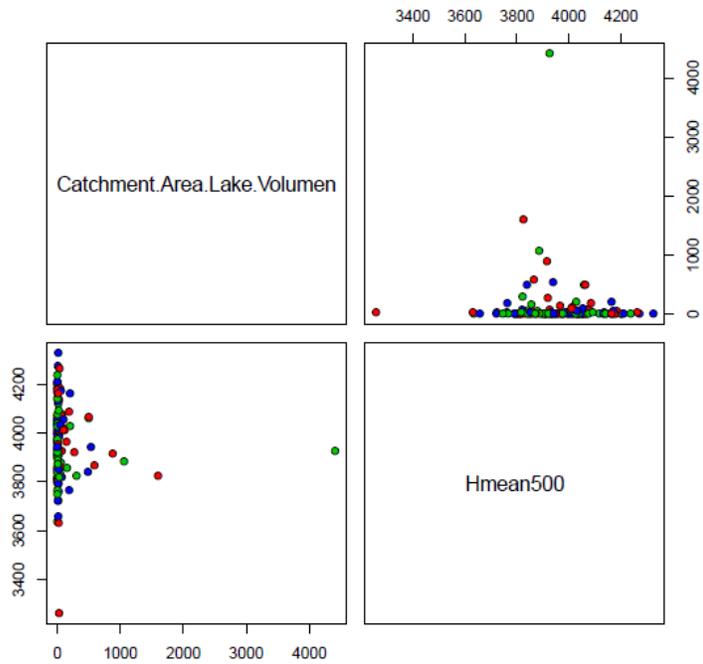




Variables de los Lagos

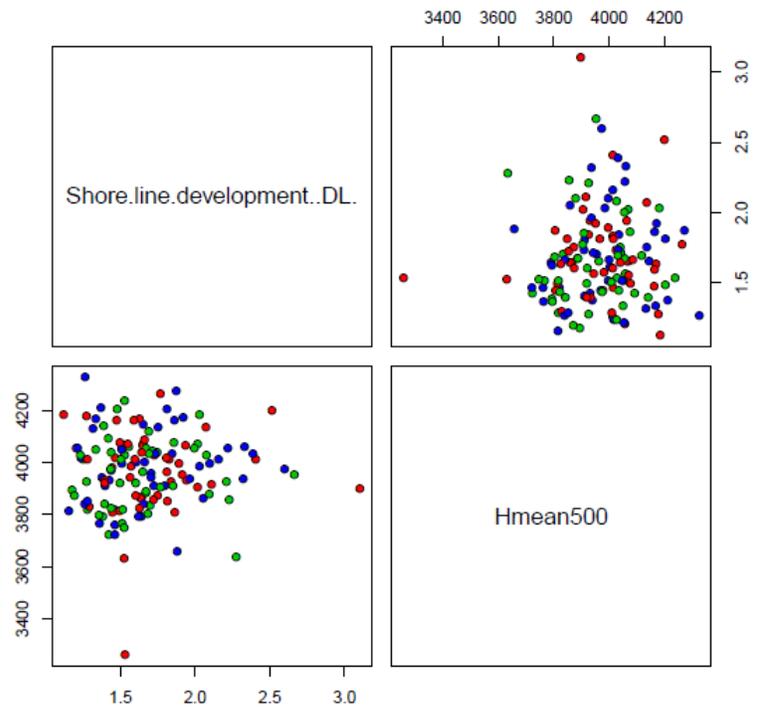


Variables de los Lagos

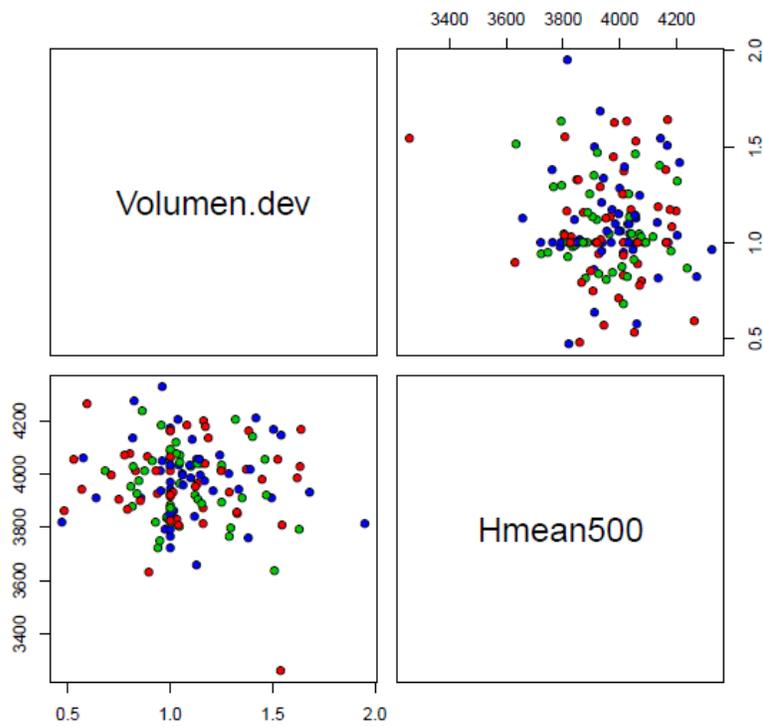




Variables de los Lagos

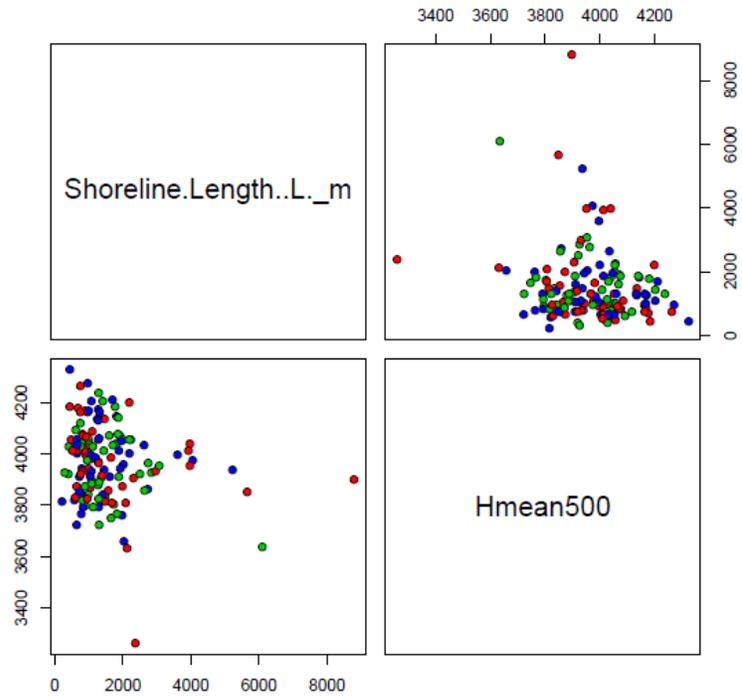


Variables de los Lagos

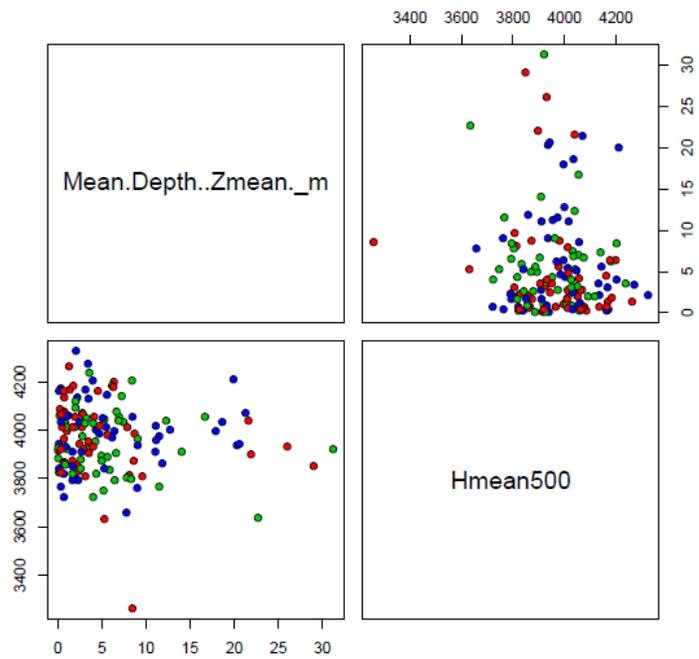




Variables de los Lagos

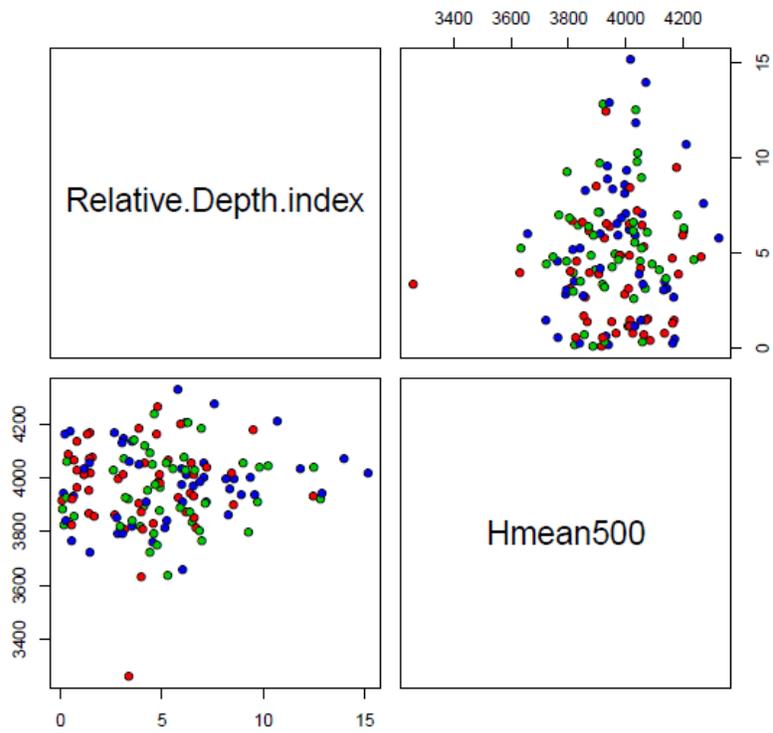


Variables de los Lagos





Variables de los Lagos



Variables de los Lagos

