

# Tesis de Doctorado en Ingeniería

**Tecnologías Multimodales para el Monitoreo y  
Caracterización Avanzado de Escenarios  
Hídricos.**

Ing. Steven Martínez Vargas

# Prefacio

Esta Tesis es presentada como parte de los requisitos para optar al grado académico de Doctor en Ingeniería, de la Universidad Nacional del Sur, y no ha sido presentada previamente para la obtención de otro título en esta Universidad u otras. La misma contiene los resultados obtenidos en investigaciones llevadas a cabo en el Instituto Argentino de Oceanografía (IADO - CONICET) durante el período comprendido entre el día 1 de Septiembre de 2019 y el 30 de Abril de 2024, bajo la dirección del Dr. Alejandro Vitale, Profesor Adjunto del Departamento de Ingeniería Eléctrica y de Computadoras, Profesor del Departamento de Geografía y Turismo e Investigador Independiente del CONICET, y bajo la codirección del Dr. Claudio Delrieux, profesor titular del Departamento de Ingeniería Eléctrica y de Computadoras e Investigador Principal del CONICET.

Ing. Steven Martinez Vargas  
stevenmv.91@gmail.com

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y DE COMPUTADORAS  
UNIVERSIDAD NACIONAL DEL SUR  
Bahía Blanca, 30/07/2024



UNIVERSIDAD NACIONAL DEL SUR  
Secretaría General de Posgrado y Educación Continua

La presente tesis ha sido aprobada el .../.../..... , mercedo la calificación de .....(.....)

# Agradecimientos

Agradezco profundamente al Dr. Claudio Delrieux, mi codirector, por su persistencia, insistencia y acompañamiento que permitió brindarme la posibilidad de desarrollar mis estudios de doctorado en Argentina.

Expreso mi gratitud al Dr. Alejandro Vitale, mi director, y al Instituto Argentino de Oceanografía por su orientación y colaboración que permitió la realización de esta tesis.

Gracias a la Universidad Nacional del Sur y al Departamento de Ingeniería Eléctrica y de Computadoras por haberme permitido cursar el Doctorado y ser parte del núcleo docente del departamento.

Agradezco al Laboratorio de Ciencias de las Imágenes por la invaluable experiencia y conocimientos adquiridos durante mi participación en sus diversas líneas de investigación. Así como a todos mis colegas, por su gran calidad humana.

Dedico un especial agradecimiento a Katherym por haber sido mi pilar y compañera de travesías durante estos últimos años, y a mi querido Odín por ser una fuente de alegría y compañía.

No puedo dejar de mencionar el apoyo incondicional de mis padres, Benjamin y Flor Marina, y mi hermana, Nataly, quienes han estado presentes a pesar de la distancia.

Finalmente, agradezco a CONICET y al pueblo argentino por otorgarme la beca doctoral que hizo posible la realización de esta tesis y la contribución a la ciencia en Argentina.

# Resumen

La caracterización y el monitoreo de cuerpos de agua son esenciales para la gestión y conservación de recursos hídricos, impactando significativamente en la calidad del agua y la protección de ecosistemas. No obstante, los métodos tradicionales enfrentan limitaciones financieras, tecnológicas, científicas y de recursos humanos.

El objetivo de esta tesis es desarrollar enfoques tecnológicos integrales que mejoren significativamente la cantidad y precisión de la batimetría y las mediciones de los parámetros de calidad del agua. Para lograr esto, se desarrolló un vehículo de superficie no tripulado (USV) para la medición y monitoreo in situ de datos batimétricos y parámetros de calidad del agua mediante rutas programadas o teledirigidas en distintos entornos hídricos. Además, se proponen metodologías para obtener modelos batimétricos de diversas resoluciones espaciales mediante la integración de tecnologías multimodales, como imágenes hiperspectrales aéreas y satelitales, vehículos no tripulados y algoritmos de aprendizaje de maquina. Estas tecnologías permitirán la creación de mapas precisos a diversas escalas.

El vehículo desarrollado se denomina EMAC-USV v2.0. Se caracteriza por ser modular, de bajo costo y con arquitectura abierta. Este vehículo ofrece una solución flexible para registrar datos georreferenciados de diversos sensores, tanto locales como comerciales. Estos sensores permiten medir parámetros como batimetría, temperatura, sólidos en suspensión, entre otros. EMAC-USV v2.0 se destaca por su diseño equilibrado, optimizando rendimiento, comunicaciones, capacidad de carga útil y versatilidad en sus mediciones.



La metodología para obtener modelos batimétricos se divide en dos estudios. En el primero, se integran imágenes hiperespectrales aéreas capturadas por un vehículo aéreo no tripulado con datos de sonar en un área de 800 m<sup>2</sup> del estuario de Bahía Blanca. El modelo óptimo, basado en bosques aleatorios (RF), logró predicciones de profundidad con una desviación cuadrática media (RMSE) de 0.166 m y un coeficiente de determinación ( $R^2$ ) de 0.815, obteniendo una batimetría densa del área de estudio con una resolución de 3.6 cm por píxel utilizando los valores digitales de las bandas espectrales. El segundo estudio fusiona imágenes satelitales hiperespectrales (VNIR) con datos batimétricos de una carta náutica para generar una batimetría de alta resolución en un área de aproximadamente 4000 km<sup>2</sup> en la Bahía Samborombón, provincia de Buenos Aires. Para aumentar la resolución espacial de las bandas espectrales, se implementó el método de fusión pancromática basado en PCA. Los modelos óptimos, también basados en RF, permitieron obtener batimetrías a escalas de 30 m y 5 m por píxel. Donde el modelo de mayor resolución obtuvo un  $R^2$  de 0.869 y un RMSE de 1.109 m, utilizando solo 24 de las 63 bandas espectrales disponibles del satélite.

Esta tesis representa un avance significativo en el campo de los estudios hídricos, abordando los desafíos del monitoreo y caracterización de cuerpos de agua mediante el desarrollo de plataformas no tripuladas para la adquisición eficiente de parámetros de calidad del agua y batimetría en diversos entornos hídricos. Así como la fusión de datos hiperespectrales y batimétricos a través de modelos de aprendizaje de máquina optimizados que permiten obtener mapas batimétricos de alta resolución en zonas costeras someras.

# Abstract

The characterization and monitoring of water bodies are essential for the management and conservation of water resources, significantly impacting water quality and the protection of ecosystems. However, traditional methods face financial, technological, scientific and human resource limitations.

The objective of this thesis is to develop comprehensive technological approaches that significantly improve the quantity and accuracy of bathymetry and water quality parameter measurements. To achieve this, an unmanned surface vehicle (USV) was developed for in situ measurement and monitoring of bathymetric data and water quality parameters through programmed or remotely piloted routes in different water environments. In addition, methodologies are proposed to obtain bathymetric models of various spatial resolutions by integrating multimodal technologies, such as airborne and satellite hyperspectral imagery, unmanned vehicles and machine learning algorithms. These technologies will enable the creation of accurate maps at various scales.

The developed vehicle is called EMAC-USV v2.0. It is characterized by being modular, low cost and open architecture. This vehicle offers a flexible solution to record georeferenced data from various sensors, both local and commercial. These sensors can measure parameters such as bathymetry, temperature, suspended solids, among others. EMAC-USV v2.0 stands out for its balanced design, optimizing performance, communications, payload capacity and versatility in its measurements.

The methodology to obtain bathymetric models is divided into two studies. In the first one, airborne hyperspectral images captured by an unmanned aerial vehicle are integrated with sonar data over an 800 m<sup>2</sup> area of the Bahía Blanca estuary. The optimal model, based on random forests (RF), achieved depth predictions with a root mean square deviation (RMSE) of 0.166 m and a coefficient of determination ( $R^2$ ) of 0.815, obtaining a dense bathymetry of the study area with a resolution of 3.6 cm per pixel using the digital values of the spectral bands. The second study fuses hyperspectral satellite imagery (VNIR) with bathymetric data from a nautical chart to generate high-resolution bathymetry over an area of approximately 4000 km<sup>2</sup> in Samborombón Bay, Buenos Aires province. To increase the spatial resolution of the spectral bands, the PCA-based panchromatic fusion method was implemented. The optimal models, also based on RF, allowed obtaining bathymetries at scales of 30 m and 5 m per pixel. Where the highest resolution model obtained an  $R^2$  of 0.869 and an RMSE of 1.109 m, using only 24 of the 63 available satellite spectral bands.

This thesis represents a significant advance in the field of water studies, addressing the challenges of monitoring and characterization of water bodies through the development of unmanned platforms for the efficient acquisition of water quality and bathymetry parameters in various water environments. As well as the fusion of hyperspectral and bathymetric data through optimized machine learning models that allow obtaining high resolution bathymetric maps in shallow coastal areas.

# Índice general

<b>Índice de figuras</b>	<b>XI</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Caracterización y monitoreo de escenarios hídricos . . . . .	1
1.2. Objetivos de la tesis . . . . .	7
1.2.1. Objetivo general . . . . .	7
1.2.2. Objetivos específicos . . . . .	7
1.3. Estructura de la tesis . . . . .	8
<b>2. Marco conceptual</b>	<b>9</b>
2.1. Batimetría . . . . .	9
2.2. Parámetros de calidad del agua . . . . .	10
2.3. Imágenes hiperespectrales . . . . .	11
2.3.1. Imágenes hiperespectrales en la caracterización de los cuerpos de agua . . . . .	14
2.4. Fusión pancromática . . . . .	16
2.4.1. Pansharpening mediante análisis de componentes principales . . . . .	18
2.5. Modelos de aprendizaje de máquina implementados . . . . .	19
2.5.1. Bosques aleatorios . . . . .	19
2.5.2. Máquinas de soporte vectorial . . . . .	22
2.6. Métodos de interpolación para generar mapas batimétricos . . . . .	24

<b>3. Desarrollo de tecnologías: Plataforma de monitoreo y adquisición de datos multiparamétrica de código abierto y bajo costo</b>	<b>26</b>
3.1. EMAC-USV versión inicial . . . . .	28
3.2. EMAC-USV v2.0 . . . . .	30
3.2.1. Estructura del vehículo y limitaciones de diseño . . . . .	31
3.2.2. Unidad de adquisición de datos . . . . .	34
3.2.3. Sensores . . . . .	37
3.2.4. Unidad de control y comunicaciones . . . . .	39
3.2.5. Unidad de control y monitoreo de misiones . . . . .	40
3.3. Construcción del vehículo . . . . .	42
3.3.1. Casco . . . . .	42
3.3.2. Unidad de adquisición de datos y sensores . . . . .	42
3.3.3. Montaje . . . . .	44
3.4. Instrucciones de operación . . . . .	44
3.5. Resultados . . . . .	46
3.5.1. Validación y caracterización . . . . .	46
<b>4. Integración de tecnologías: Batimetría hiperespectral</b>	<b>53</b>
4.1. Batimetría densa en zonas costeras turbias a partir de imágenes hiperespectrales aéreas . . . . .	54
4.1.1. Área de estudio . . . . .	56
4.1.2. Batimetría USV . . . . .	56
4.1.3. Datos hiperespectrales UAV . . . . .	57
4.1.4. Procesado de datos . . . . .	60
4.1.5. Entrenamiento de los modelos . . . . .	63
4.1.6. Resultados del entrenamiento y evaluación de los modelos . . . . .	64
4.1.7. Estudio de ablación batimétrico . . . . .	67
4.1.8. Estudio de ablación hiperespectral . . . . .	70

4.1.9. Validación geomorfológica de los modelos batimétricos . . . . .	74
4.1.10. Batimetría densa del área de estudio . . . . .	80
4.2. Batimetría de alta resolución en zonas costeras turbias a partir de imágenes satelitales hiperespectrales . . . . .	81
4.2.1. Área de estudio . . . . .	83
4.2.2. Datos batimétricos . . . . .	84
4.2.3. Datos satelitales hiperespectrales . . . . .	87
4.2.4. Procesado de datos . . . . .	89
4.2.5. Entrenamiento de los modelos . . . . .	94
4.2.6. Resultados del entrenamiento y evaluación de los modelos . . . . .	95
4.2.7. Estudio de ablación hiperespectral . . . . .	97
4.2.8. Optimización de los modelos . . . . .	98
4.2.9. Validación de los modelos . . . . .	104
4.2.10. Batimetría en resolución hiperespectral satelital y alta resolución pancromática del área de estudio . . . . .	106
<b>5. Conclusiones y trabajo futuro</b>	<b>111</b>
5.1. Conclusiones . . . . .	111
5.2. Trabajo futuro . . . . .	115
<b>A. Contribuciones</b>	<b>117</b>
A.1. Artículos en revistas indexadas . . . . .	118
A.2. Artículos en conferencias nacionales e internacionales . . . . .	118
A.3. Difusión en medios . . . . .	119
A.4. Distinciones . . . . .	120

# Índice de figuras

2.1. Principio de funcionamiento básico de una ecosonda monohaz. De Wikimedia Commons, el repositorio multimedia libre. Autor: Brandon T. Fields (cdated) (CC0-1.0). . . . .	10
2.2. Diferencias entre imágenes de una sola banda, multiespectrales e hiperespectrales. De Wikimedia Commons, el repositorio multimedia libre. Autor: Lucasbosch (CC-BY-SA-4.0). . . . .	12
2.3. Espectro de las imágenes hiperespectrales. . . . .	13
2.4. Ejemplo de espectro de reflectancia del agua para cinco clasificaciones ópticas (OWT) (Udeberg et al., 2019). . . . .	15
2.5. Esquema de la metodología de fusión pancromática a partir de una imagen hiperespectral y pancromática. . . . .	17
2.6. Comparación entre árboles de decisión y bosques aleatorios. De Wikimedia Commons, el repositorio multimedia libre. Autor: Jeremybeauchamp (CC-BY-SA-4.0). . . . .	20
2.7. Máquinas de soporte vectorial (SVM): Hiperplano de margen máximo y márgenes para las SVM entrenadas con dos clases. Las muestras en los márgenes se denominan vectores de soporte ( $w$ es un vector de pesos, $x$ es el vector de entrada y $b$ es el sesgo). De Wikimedia Commons, el repositorio multimedia libre. Autor: Larhmam (CC-BY-SA-4.0). . . . .	23

2.8. Comparación de métodos de interpolación: (a) Interpolación lineal. (b) IDW. (c) Kriging. De Wikimedia Commons, el repositorio multimedia libre. Autor: Helena Mitsova (CC-BY-3.0). . . . .	25
3.1. Primera versión del vehículo de superficie no tripulado (USV) perteneciente a la familia de Estaciones de Monitoreo Ambiental y Costero (EMAC) en el IADO-CONICET denominado EMAC-USV: (a) Vista exterior. (b) Sistema de propulsión basado en un único propulsor y un sistema de dirección de doble timón. . . . .	29
3.2. Diagrama que describe la arquitectura software/hardware de EMAC-USV v2.0: (a) Unidad de Control y Comunicaciones. (b) Unidad de Adquisición de Datos y Sensores. (c) Unidad de Control y Monitoreo de Misiones. . . . .	30
3.3. Diseño renderizado de EMAC-USV v2.0 en diferentes vistas: (a,b) vistas laterales. (c) vista inferior. (d) vista superior. (e) vista posterior. (f) vista frontal. . . . .	33
3.4. Unidad de Adquisición de Datos: (a) circuito esquemático. (b) implementación de la placa de circuito. (c) caja de la UAD. . . . .	35
3.5. Diagrama de flujo que describe el funcionamiento de la Unidad de Adquisición de Datos. . . . .	36
3.6. Ecosonda Ping Sonar monohaz (Blue Robotics). . . . .	37
3.7. Sensores: (a) Temperatura. (b) Concentración de Sólidos en Suspensión. . .	38
3.8. Sensor de Concentración de carbono orgánico (Turner Designs). . . . .	39
3.9. Arquitectura de la Unidad de Control y Comunicaciones de EMAC-USV-v2.0.	40
3.10. Aplicación móvil EMAC Monitor: (a) modo espera. (b) registrando datos. .	41



3.11. Vista de montaje de todos los componentes de EMAC-USV v2.0 y actualización del firmware: (a) Principales componentes internos. (b) Propulsores y sensores. (c) Puertos de configuración de la UAD. (d) Puerto de sensores de la UAD. (e) Conexión de alimentación. (f) Modo de actualización del firmware de la UAD. (g) Modo de actualización del firmware mediante conexión a PC. (h - i) Archivos de sensores. (j) Actualizador del firmware mediante Arduino IDE. . . . .	43
3.12. Diferentes vistas de EMAC-USV v2.0: (a) USV antes de su puesta en funcionamiento. (b) Partes interiores del USV. (c) USV en funcionamiento. . .	46
3.13. Ejemplo de la trayectoria diseñada en el escenario N° 1 (Estanque 1) utilizando el software Mission Planner. . . . .	47
3.14. Estanque 1 (partes izquierda y derecha) (a-d) y Estanque 2 (e-h): (a,e) Trayectoria del USV y mapas batimétricos. (b,f) Mapas de temperatura. (c,g) Mapas de concentración de sólidos en suspensión (CSS). (d,h) Datos completos de eco-respuesta pertenecientes a un transecto de cada estanque (ver línea roja en las Figuras. a y e). . . . .	49
3.15. Evaluación de los datos batimétricos de EMAC-USV v2.0 mediante los datos de la ecosonda multihaz de banda ancha (modelo Sonyc2020). . . . .	51
3.16. Mediciones de batimetría, temperatura, concentración de sólidos en suspensión (CSS) y concentración de carbono orgánico (CCO) en la parte interna del Canal Principal del Estuario de Bahía Blanca (Argentina). . . . .	52
4.1. Batimetría a partir de la fusión de imágenes hiperespectrales aéreas y mediciones de ecosonda mediante modelos de aprendizaje de maquina: Diagrama de flujo de las etapas y metodología propuesta . . . . .	55
4.2. Área de Estudio: (a) (Izq) Estuario de Bahía Blanca (Fuente: Instituto Argentino de Oceanografía); (b) (Der) Mapa de localización, Puerto de Cuarteros (Fuente: Google Earth). . . . .	56

4.3. Transectos de batimetría en el área de estudio sobre una imagen a pseudocolor adquiridos mediante un sonar abordo del vehículo EMAC-USV. Los puntos en color y de forma circular representan las mediciones con profundidad mayor (azul), media (amarillo) y menor (magenta). . . . .	58
4.4. Adquisición de imágenes hiperespectrales: (a) Cámara hiperespectral Rikola. (b) Vehículo aéreo no tripulado (UAV). . . . .	59
4.5. Diferencias espectrales para la zona de estudio: Vista de diferentes bandas hiperespectrales (a) 500 nm. (b) 628 nm. (c) 710 nm. (d) 892 nm. (e) Reflectancia para los puntos batimétricos de profundidad menor, media y mayor marcados en la Figura 4.3. . . . .	62
4.6. Identificación de puntos con error absoluto mayor a 0.2 m en la predicción del modelo batimétrico RF marcados sobre la pseudoimagen en color negro. . . . .	65
4.7. Resultados de los modelos batimétricos basados en imágenes hiperespectrales aéreas y mediciones de ecosonda para bosques aleatorios (RF) y máquinas de soporte vectorial (SVM) (profundidad estimada frente a profundidad de referencia en el entrenamiento y la validación de los modelos, y diagrama de Bland-Altman): (a, b) RF. (c, d) SVM. . . . .	66
4.8. Pruebas de ablación: (a) Por transectos TAB Y TDE. (b) Por zonas de: (Izq) Mayor profundidad; (Cen) Profundidad intermedia; (Der) Profundidad superficial. . . . .	67
4.9. Profundidad predicha por los modelos batimétricos por Transectos y Zonas vs profundidad real para el conjunto de datos de testeo (TAB) Transectas A y B. (TDE) Transectas D y E. (S) Profundidad superficial. (I) Profundidad intermedia. (D) Mayor profundidad: (a) Bosques aleatorios (RF). (b) Máquinas de soporte vectorial (SVM). . . . .	69

4.10. Profundidad predicha por los modelos batimétricos por zonas vs profundidad real para otras zonas. (D) Zona de mayor profundidad. (S) Zona de menor profundidad: (a) Bosques aleatorios (RF). (b) Maquinas de soporte vectorial (SVM). . . . .	70
4.11. Estudio de ablación hiperspectral sobre el modelo RF: Bandas más influyentes mediante la permutación de atributos, su importancia se muestra en orden ascendente. (a) Importancia por permutación sobre el conjunto de datos de validación. (b) Importancia por permutación sobre el conjunto de datos de entrenamiento. . . . .	71
4.12. Gráficas SHAP de incidencia de las bandas espectrales para el modelo basado en bosques aleatorios (RF): (a)Modelo área total. (b) Modelo transectas AB. (c) Modelo transectas DE. (d) Modelo zona superficial. (e) Modelo zona intermedia. (f) Modelo zona profunda. . . . .	73
4.13. Validación de los modelos RF y SVM para las cinco transectas de referencia (se compara la predicción de los modelos con respecto a el método de interpolación kriging (K) y a las mediciones batimétricas). . . . .	76
4.14. Demarcación de las transectas de prueba para la evaluación geomorfológica de los modelos batimetricos. . . . .	77
4.15. Perfiles previstos del fondo marino por los modelos de bosques aleatorios (RF), maquinas de soporte vectorial (SVM) e interpolación kriging (K) para las cinco transectas de prueba. . . . .	78
4.16. Batimetría densa del área de estudio basado en imágenes hiperspectrales aéreas y mediciones de ecosonda a bordo del vehículo EMAC-USV. . . . .	80
4.17. Batimetría satelital hiperspectral: Metodología para obtener batimetrías de alta resolución a partir de la fusión de imágenes satelitales y datos batimétricos. . . . .	82

4.18. Área de estudio: Bahía Samborombón (marcada en la zona central), Punta Rasa (enmarcada en la zona inferior derecha). Fuente: Áreas Costeras y Marinas Protegidas de la Argentina ( <u>AMP</u> ). . . . .	83
4.19. Mapa batimétrico de referencia georreferenciado de la Bahía Samborombón.	85
4.20. Puntos batimétricos georreferenciados (en color amarillo se marcaron los puntos que serán usados como transecta de validación). . . . .	86
4.21. Capturas hiperespectrales del satélite PRISMA en el área de estudio. Se destacan en color las siguientes capturas: (a) Captura interna de la Bahía Samborombón. (b) Captura ubicada en Punta Rasa (ver Figura 4.18). . . . .	88
4.22. Visualización de datos del satélite PRISMA sobre la captura de la Figura 4.21b, (Vista alejada y ampliada): (a, c) Banda hiperespectral (716 nm) (30 m por píxel). (b, d) Imagen pancromática (5 m por píxel). . . . .	90
4.23. Visualización de la banda 628 nm sobre la captura de la Figura 4.21b en resolución PRISMA (PRS-HSI) y Pancromática (HSI(PS)). Vistas a diferentes distancias: I(a, b, c) PRS-HSI (30 m por píxel). II(a, b, c) HSI(PS) (5 m por píxel). . . . .	92
4.24. Espectro de Reflectancia VNIR para los puntos de profundidad menor, media y mayor de los conjuntos hiperespectrales PRS-HSI y HSI(PS). . . . .	94
4.25. Resultados de los modelos batimétricos basados en bosques aleatorios (RF) (Profundidad estimada frente a profundidad de referencia en el entrenamiento y la validación de los modelos, y diagrama de Bland-Altman): (a, b) RF-PRS-HSI. (c, d) RF-HSI(PS). . . . .	96
4.26. Gráficas SHAP de las bandas más incidentes en los modelos basados en bosques aleatorios (RF): (a, b) Conjunto de datos PRS-HSI. (c, d) Conjunto de datos HSI(PS). . . . .	99

4.27. Comparación entre de los modelos basados en bosques aleatorios (RF-PRS-HSI y RF-HSI(PS)) sin optimizar (63 bandas) y (RF-PRS-HSI-O51 y RF-HSI(PS)-O24) optimizados (51 y 24 bandas respectivamente): (a, c) Profundidad estimada frente a profundidad de referencia. (b, d) Diagrama Bland-Altman. . . . .	103
4.28. Validación de los modelos batimétricos basados en bosques aleatorios: modelos base (RF-PRS-HSI y RF-HSI(PS)), modelos optimizados (RF-PRS-HSI-O51 y RF-HSI(PS)-O24) y el método de interpolación kriging (K). Para la transecta de validación marcada en amarillo del área de estudio (ver Figura 4.20) . . . . .	105
4.29. Predicción de los modelos batimétricos optimizados (RF) y el método de interpolación kriging (K) para la captura hiperespectral de la Figura 4.21a (área: 900 km <sup>2</sup> ): I (resolución 30 m por píxel). I(a) RF-PRS-HSI-O51. I(b) K. I(c) Diferencia entre RF-PRS-HSI-O51 y K. II (resolución 5 m por píxel). II(a) RF-HSI(PS)-O24. II(b) K. II(c) Diferencia entre RF-HSI(PS)-O24 y K. . . . .	107
4.30. Mapa batimétrico del modelo RF-PRS-HSI-O51 (resolución 30 m por píxel) para todas las capturas hiperespectrales de la Figura 4.21 correspondientes al área de estudio (Bahía Samborombón) cubriendo una superficie de aproximadamente 4000 km <sup>2</sup> . . . . .	109
4.31. Mapa batimétrico del modelo RF-HSI(PS)-O24 (resolución 5 m por píxel) para todas las capturas hiperespectrales de la Figura 4.21 correspondientes al área de estudio (Bahía Samborombón) cubriendo una superficie de aproximadamente 4000 km <sup>2</sup> . . . . .	110

# Capítulo 1

## Introducción

### 1.1. Caracterización y monitoreo de escenarios hídricos

La caracterización y el monitoreo de los cuerpos de agua son fundamentales para la gestión y conservación de los recursos hídricos. Según [Chapman et al. \(2021\)](#) el monitoreo del agua se lleva a cabo con el propósito de determinar la calidad y/o cantidad del agua. En 1992, el programa GEMS/Water (Sistema Global de Monitoreo Ambiental para el Agua) de la ONU, junto con el Programa Hidrológico Internacional de la UNESCO, produjo un completo manual sobre la evaluación de la calidad del agua, que se actualizó en 1996 ([Chapman et al., 2021](#)). A su vez, un estudio de la Organización Mundial de la Salud ([Bartram and Ballance, 1996](#)) destaca todo el proceso de monitoreo proporcionando una guía detallada para la implementación de una red de monitoreo con descripciones paso a paso de los métodos de campo y de laboratorio.

La gestión del agua se centra en equilibrar las necesidades de agua para diversos propósitos, como el saneamiento, la producción de energía, y la protección del ecosistema ([Anisfeld, 2011](#)). El monitoreo adecuado de los parámetros de calidad del agua es esencial para obtener información, elaborar planes de manejo, y tomar decisiones apro-

piadas (Yanes Luis et al., 2022). Sin embargo, el monitoreo del agua a menudo presenta una serie de desafíos. Estos desafíos incluyen entre otros las características intrínsecas del campo de estudio (como la hidrodinámica, el área y la profundidad) (Bangira et al., 2019; Branchet et al., 2021), los recursos financieros disponibles (Strobl and Robillard, 2008; Matsushita et al., 2016), políticas científicas e innovadoras (Carvalho et al., 2019; Smyth et al., 2021), entre otros. Las características más comunes para describir los cuerpos de agua incluyen tamaño y forma, ubicación geográfica, origen y tipo, calidad del agua, clima y temperatura, vegetación y vida animal, ciclos hidrológicos, usos humanos, ecosistemas circundantes y cambios estacionales (McElarney and Rippey, 2009; Scholz and Yang, 2010). La caracterización detallada de un cuerpo de agua implica la medición y el monitoreo de múltiples parámetros que permiten comprender mejor su estado e importancia en el sistema circundante. Dentro de la caracterización de escenarios hídricos la profundidad que es obtenida a través de la batimetría es uno de los parámetros de mayor relevancia. Gracias a los estudios batimétricos es posible generar mapas que describen la topografía subacuática de los cuerpos de agua, además de poder calcular áreas y volúmenes con mayor precisión.

La medición de datos batimétricos y parámetros de calidad del agua requiere medios adecuados para realizar estas mediciones de manera eficiente en diversos escenarios hídricos. Generalmente, estos medios consisten en plataformas o embarcaciones de mediano tamaño que incorporan sensores, sistemas de adquisición de datos y sistemas de posicionamiento global (GPS). Estas plataformas, que pueden ser tripuladas o no, se han desarrollado principalmente para monitorear entornos acuáticos. El desarrollo de plataformas no tripuladas es un campo emergente de gran interés para los investigadores en recursos hídricos. Sousa and Andrade Gonçalves (2010) señalaron que las futuras generaciones de vehículos no tripulados deberían enfocarse en mayor autonomía, menor costo, mayor resistencia y capacidad de conexión en red. Se están investigando ampliamente diversos temas relacionados con el monitoreo del agua, como la comunicación (Zolich et al.,

2018; Chen et al., 2021), la ingeniería (Shao et al., 2019; Francis and Traykovski, 2021), el control de navegación (Villa et al., 2016; Carlson et al., 2019), los materiales compuestos (Odetti et al., 2020) y los sistemas de energía (Rybin et al., 2020; Graves et al., 2021; Touzout et al., 2021). El desarrollo de vehículos de superficie no tripulados ha sido objeto de investigaciones destacadas. Por ejemplo, Jo et al. (2019) presentaron una plataforma de bajo costo, pequeña y de código abierto para medir la calidad del agua cerca de la superficie. Carlson et al. (2019) desarrollaron un USV asequible y portátil para medir batimetría y corrientes oceánicas en entornos peligrosos, como áreas someras y rocosas, de manera segura. Madeo et al. (2020) crearon un vehículo de superficie utilizando componentes de bajo costo disponibles en el mercado, enfatizando su replicabilidad para establecer una red social de sensores. Los USV comerciales son costosos para investigaciones, especialmente en países en vías de desarrollo (Gregory and Vardy, 2020), con precios que varían desde varios miles hasta cientos de miles de dólares, dependiendo de los sensores a bordo. Además, muchas plataformas emergentes no son completamente de código abierto, lo que dificulta la personalización para los usuarios finales (Jo et al., 2019).

Para superar dichas limitaciones, esta tesis propone el desarrollo de una nueva versión del vehículo EMAC-USV (EMAC: Estaciones de Monitoreo Ambiental Costero) que se desarrolló en el Instituto Argentino de Oceanografía (IADO-CONICET), el cual permitía únicamente el registro de mediciones de batimetría a través de una sonda Garmin de 200 kHz y contaba con un sistema de propulsión basado en un único motor y un sistema de doble timón, que tenía un rango de giro limitado (menor a  $45^\circ$ ). La nueva versión propuesta, denominada EMAC-USV v2.0, es un vehículo modular, de bajo costo y totalmente de código abierto que permite la integración de múltiples sensores y puede ser fácilmente replicado. Esto facilitará el monitoreo de múltiples parámetros de calidad del agua y el registro de mediciones de batimetría georreferenciados.

Las mediciones batimétricas precisas y densas desempeñan un papel de gran importancia en la gestión y planificación costera, particularmente en zonas con un intenso tráfico



marítimo (Su et al., 2008). Estas mediciones son esenciales en entornos estuariales complejos y dinámicos, donde se llevan a cabo investigaciones ambientales, geomorfológicas y biológicas (Stumpf et al., 2003). El estuario de Bahía Blanca, ubicado en la Provincia de Buenos Aires, Argentina, es un ejemplo paradigmático de un entorno costero extenso y complejo, abarcando más de 2500 km<sup>2</sup> de llanuras intermareales, canales interconectados, islas, lagunas, y marismas salinas (Marcovecchio and Ferrer, 2005; Piccolo et al., 2008). Los ciclos de marea en este estuario generan efectos erosivos y transportan sedimentos significativos (Popovich, 2008), lo que no solo reduce la transparencia del agua, sino que también altera la morfología geográfica (Revollo et al., 2019). Una de las principales limitaciones en la investigación ambiental de estuarios como el de Bahía Blanca radica en la falta de información batimétrica precisa y extensa. La exactitud en la estimación de la profundidad del agua es fundamental para abordar problemas como inundaciones, erosión costera y la preservación de hábitats ecológicos. Las técnicas de batimetría tradicional, como el uso de cables, varillas o dispositivos ultrasónicos, proporcionan mediciones puntuales que resultan costosas y laboriosas cuando se requieren mediciones densas en áreas extensas, además de plantear riesgos operativos en aguas poco profundas (Papadopoulou et al., 2015; Wang et al., 2020). En contraste, enfoques más recientes se basan en dispositivos activos avanzados como las ecosondas multihaz, que proporcionan mediciones más densas, o el uso de dispositivos sensores LiDAR aéreotransportados. Este último método aprovecha las variaciones en las propiedades ópticas del agua a diferentes longitudes de onda. Por esta razón, se utilizan típicamente dos haces en la región del infrarrojo cercano (1064 nm) y el verde visible (532 nm) en cuerpos de agua sobre capas bentónicas (Allouis et al., 2010; Kakuta et al., 2018), especialmente en áreas donde la navegación es difícil o riesgosa. Sin embargo, este enfoque es efectivo solo en áreas relativamente pequeñas debido a los costos operativos asociados, y puede arrojar resultados deficientes en regiones donde el agua es turbia en las longitudes de onda mencionadas, o cuando transporta sedimentos en suspensión (Wang et al., 2020). Un enfoque emergente y prometedor en esta área es el

uso de sensores hiperspectrales pasivos ligeros, que se pueden acoplar de manera eficiente a vehículos aéreos no tripulados (UAVs). Esta tecnología permite la obtención de imágenes de alta resolución en diversas bandas ópticas a un costo operativo significativamente reducido (Stumpf et al., 2003; Su et al., 2008; Wang et al., 2020). La justificación de este enfoque se basa en el principio de que la radiación solar retrodispersada reflejada desde una superficie uniformemente reflectante depende de una función exponencial negativa de la profundidad del agua (Lyzenga, 1981, 1985). Este principio permite el diseño metodológico de estimaciones batimétricas densas basadas en imágenes. No obstante, este enfoque presenta desafíos significativos en términos de calibración y corrección, debido a la complejidad de los fenómenos físicos involucrados, ya que las mediciones reales están sujetas a una superposición de fenómenos físicos difíciles de modelar y ajustar en conjunto, incluyendo la distribución de la radiancia espectral diurna, la corrección atmosférica, la absorción de sedimentos en suspensión, la atenuación del trayecto de la luz incidente y reflejada, y la retrodispersión, por mencionar solo las fuentes de incertidumbre más relevantes (Su et al., 2008; Papadopoulou et al., 2015). Por esta razón, la fusión de datos y su posterior análisis con modelos de aprendizaje automático parece ser una alternativa significativa en la integración de datos de imágenes hiperspectrales pasivas en la estimación batimétrica. Por ejemplo, Pan et al. (2016) utilizaron imágenes hiperspectrales junto con datos LiDAR para la detección y clasificación de la vegetación submarina. Misra et al. (2018) combinaron imágenes multiespectrales Landsat y mediciones de ecosondas mediante máquinas de soporte vectorial como predictor para la cartografía batimétrica en aguas poco profundas. Estos métodos generalmente han mostrado buenos resultados en aguas claras, pero resultados deficientes en áreas con dinámicas de mareas complejas y sedimentos en suspensión.

Para abordar esta problemática, esta tesis presenta una metodología aplicada a aguas costeras con presencia de sedimentos que combina imágenes hiperspectrales de dos fuentes principales: cámaras hiperspectrales aerotransportadas y satélites hiperspectrales,

con datos de profundidad georreferenciados provenientes de sonares, cartas náuticas u otras fuentes batimétricas. El objetivo es estudiar la viabilidad de obtener una batimetría densa y útil mediante la fusión de imágenes hiperespectrales con datos batimétricos a través de modelos de aprendizaje de maquina. La metodología se desarrolló en dos estudios. En el primero, se emplearon imágenes hiperespectrales captadas por un UAV y datos de sonar obtenidos por un USV en un área costera de aproximadamente 800 m<sup>2</sup> del estuario de Bahía Blanca, en el sudoeste de la provincia de Buenos Aires, Argentina. En el segundo, se utilizaron imágenes hiperespectrales satelitales junto con datos de profundidad provenientes de una carta náutica en un área costera de aproximadamente 4000 km<sup>2</sup> en la Bahía de Samborombón, ubicada en el noreste de la provincia de Buenos Aires.

La metodología desarrollada genera un modelo batimétrico basado en los datos batimétricos y las características de las imágenes hiperespectrales empleadas en cada lugar de estudio. La finalidad de los estudios es demostrar cómo la misma metodología se puede aplicar tanto en pequeñas áreas (m<sup>2</sup>) como en grandes superficies (km<sup>2</sup>), así como en diferentes zonas de estudio, mediante el uso de tecnologías adecuadas para tal fin. Los modelos batimétricos obtenidos permiten generar mapas batimétricos del área de estudio con la resolución espacial de la imagen hiperespectral, e incluso a resolución pancromática en el caso de las imágenes satelitales, utilizando los números digitales de las bandas espectrales. Los resultados superan los alcances de los métodos de interpolación tradicionalmente utilizados en estudios batimétricos, que solo emplean la estadística de los valores de profundidad conocidos para generar nuevos datos. Estos métodos tradicionales requieren un gran número de mediciones para generar mapas precisos, lo cual implica campañas de recolección de datos extensas que demandan altos recursos operativos, económicos y humanos.

## 1.2. Objetivos de la tesis

### 1.2.1. Objetivo general

Investigar y desarrollar enfoques tecnológicos integrales que permitan un aumento significativo en el número y precisión de la batimetría y la medición de parámetros de calidad del agua, contribuyendo al monitoreo y caracterización de diversos escenarios hídricos.

### 1.2.2. Objetivos específicos

- Desarrollar un vehículo de superficie no tripulado (USV) para la medición y monitoreo in situ de datos batimétricos y parámetros de calidad del agua, tales como temperatura, sólidos en suspensión y concentración de carbono orgánico, entre otros. La operación del vehículo debe permitir la navegación autónoma en diversos y complejos escenarios hídricos.
- Generar mapas georreferenciados a partir de los datos recolectados por el USV que describan el estado de cada uno de los parámetros en los escenarios hídricos monitoreados.
- Generar modelos batimétricos mediante la integración de tecnologías multimodales, como imágenes hiperespectrales aéreas y satelitales, datos batimétricos, vehículos no tripulados y algoritmos de aprendizaje de maquina, facilitando la creación de mapas a diferentes escalas con alta precisión en cuerpos de agua turbia con dinámicas complejas.

### **1.3. Estructura de la tesis**

Esta tesis se desarrolla en cinco capítulos. El primer capítulo corresponde a la introducción, donde se expone la problemática abordada y los objetivos propuestos. El segundo capítulo presenta un marco conceptual, describiendo las tecnologías, métodos y algoritmos utilizados durante el desarrollo de la tesis. El tercer capítulo trata sobre el desarrollo de un vehículo de superficie no tripulado que permite el monitoreo y registro de datos batimétricos y parámetros de calidad del agua en diversos escenarios hídricos. El cuarto capítulo introduce una metodología que permite obtener modelos batimétricos a partir de la fusión de imágenes hiperspectrales aéreas o satelitales y datos de profundidad georreferenciados mediante algoritmos de aprendizaje de máquina, generando mapas batimétricos densos. Finalmente, el capítulo cinco aborda las conclusiones y trabajos futuros. Adicionalmente, en los anexos se presentan las contribuciones académicas realizadas durante el desarrollo de esta tesis.

# Capítulo 2

## Marco conceptual

### 2.1. Batimetría

La batimetría se define como la medición de la profundidad del agua en océanos, mares, lagos o cuerpos de agua. En la actualidad, existen diferentes tecnologías para realizar batimetría. Dentro de las más comunes se tienen: ecosondas, LiDAR, radar de onda corta (SWR) y satélites altímetros. Sin embargo, los más usados se basan en el uso de ecosondas, las cuales permiten conocer la profundidad en función del tiempo en que la onda emitida tarda en propagarse en el agua al rebotar en el fondo. Las ecosondas se clasifican en dos tipos, monohaz y multihaz. Las ecosondas monohaz emiten un solo pulso de ultrasonido y son principalmente utilizadas para mediciones de profundidad en áreas pequeñas. En contraste, las ecosondas multihaz emiten varios haces de sonido simultáneamente, lo que permite mapear áreas mas grandes y recopilar información detallada del fondo marino. Las ecosondas multihaz son principalmente usadas en embarcaciones de gran tamaño, como barcos o lanchas. En la Figura 2.1 puede observarse el principio de funcionamiento de una ecosonda de un solo haz.

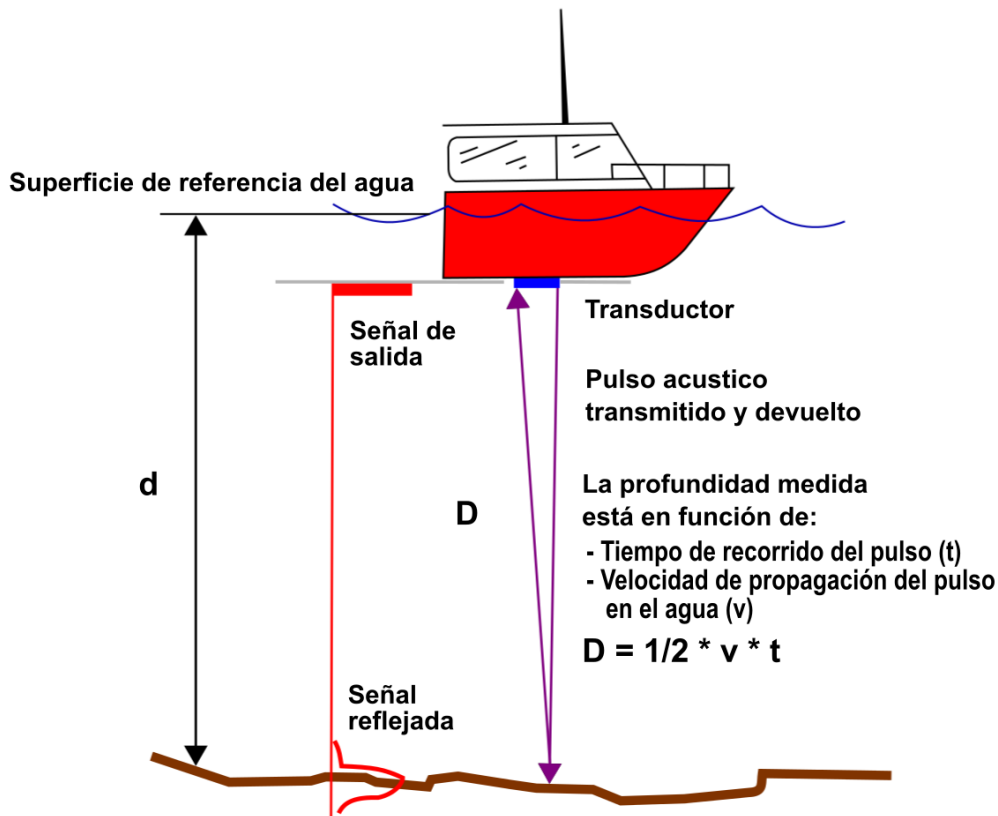


Figura 2.1: Principio de funcionamiento básico de una ecosonda monohaz. De Wikimedia Commons, el repositorio multimedia libre. Autor: Brandon T. Fields (cdated) (CC0-1.0).

## 2.2. Parámetros de calidad del agua

La calidad del agua no pudo ser evaluada cuantitativamente a lo largo de la mayor parte de la historia humana, pero las diferencias en las aguas se reconocieron por su apariencia, sabor, olor y efectos en las personas, animales y plantas (Boyd, 2018). En la actualidad, el estudio de la calidad del agua implica determinar las características químicas, físicas, y biológicas de los cuerpos de agua e identificar las posibles fuentes de contaminación que degradan la calidad del agua (Usali and Ismail, 2010). Según un estudio de Chidiac et al. (2023) el índice de calidad del agua (WQI) es una de las herramientas más utilizadas para describir la calidad del agua. El índice WQI se define como la influencia

relativa y la importancia de diferentes parámetros de calidad del agua en la calidad del agua (Kothari et al., 2021). El índice WQI suele calcularse a partir de parámetros como la temperatura, la conductividad eléctrica, la clorofila, la concentración de carbono orgánico, el pH, y la concentración de sólidos en suspensión y/o turbiedad, entre otros factores físicos, químicos, y biológicos (Gholizadeh et al., 2016; Summers, 2020; Saalidong et al., 2022). Debido a esto, es esencial contar con sensores y mecanismos para registrar los parámetros en la calidad del agua, no solo en laboratorios sino también en dispositivos móviles que permitan realizar mediciones de campo en diversos cuerpos de agua como lagos, ríos, y zonas costeras.

### 2.3. Imágenes hiperespectrales

La visión humana es capaz de percibir solo una limitada parte del espectro electromagnético (entre 380 y 780 nm) y puede distinguir entre objetos basándose en sus diferentes respuestas espectrales dentro del rango de luz visible (Land and McCann, 1971). Esto se logra gracias a las células fotorreceptoras dentro de la retina del ojo, que tienen la capacidad de absorber la luz y transformarla en señales eléctricas en el primer paso del mecanismo de visión conocido como fototransducción. De acuerdo con su morfología, las células fotorreceptoras se dividen en dos grupos. Los bastones con forma de cilindro y alta fotosensibilidad permiten la visión nocturna, aunque con una baja agudeza visual. Por otro lado, las células con forma de cono pueden detectar un amplio espectro de fotones, lo que permite la visión a color a pesar de su baja fotosensibilidad. La capacidad de detectar diferentes longitudes de onda de la luz se explica por las opsinas, tres tipos de proteínas que se encuentran en los conos. Dichas opsinas se clasifican como rojas (cono L), azules (cono S) y verdes (cono M) (Molday and Moritz, 2015; Mills et al., 2017), donde su nombre indica la sensibilidad al espectro que puede detectar cada una. La combinación de estas permite recrear la visión a color del ojo humano. Los sensores ópticos que permiten capturar imágenes digitales a color se desarrollaron basados en este principio biológico de



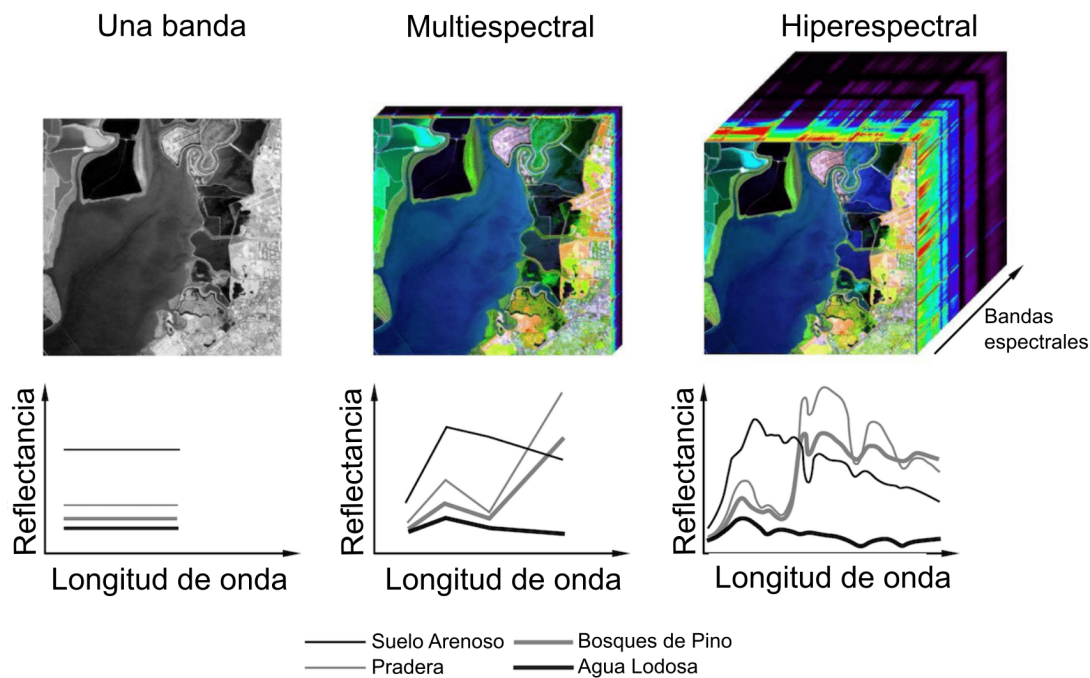


Figura 2.2: Diferencias entre imágenes de una sola banda, multiespectrales e hiperespectrales. De Wikimedia Commons, el repositorio multimedia libre. Autor: Lucasbosch (CC-BY-SA-4.0).

la visión humana. Estos registran tres bandas espectrales: rojo (R), verde (G), y azul (B), dando como resultado imágenes en el formato RGB, que pueden representar cualquier color del espectro visible al combinar estos tres canales. No obstante, la evolución de los sensores ópticos ha permitido capturar imágenes en los segmentos ultravioleta, espectro visible e incluso infrarrojos. La detección óptica pasiva se divide en imágenes de un solo canal, RGB, multiespectral y hiperespectral según las resoluciones espectrales de los sensores (Jensen, 2007). La diferencia entre imágenes de un solo canal, multiespectrales, y hiperespectrales se puede observar en la Figura 2.2.

Las imágenes multiespectrales (MSI en inglés) se obtienen a través de la captura espectral de unas pocas bandas discretas, generalmente menor a diez bandas. Estas imágenes abarcan una amplia gama espectral que va desde decenas hasta cientos de nanómetros. Sin embargo, un número limitado de bandas espectrales es un factor limitante para la discriminación de materiales. Los recientes avances en la detección hiperespectral durante las




Figura 2.3: Espectro de las imágenes hiperespectrales.

últimas dos décadas han permitido la adquisición de cientos de bandas espectrales (Khan et al., 2018). Dado que se detectan señales espectrales en una serie de canales continuos con un ancho de banda espectral estrecho generalmente inferior a 10 nm, se pueden capturar características de los objetivos a una escala fina (Sahoo et al., 2015).

Las imágenes se conforman mediante una estructura que se conoce como hipercubo, en la cual las dos primeras dimensiones representan las dimensiones espaciales de la escena y la tercera la dimensión espectral, que puede contener desde una banda, hasta cientos de bandas como en el caso de las imágenes hiperespectrales (HSI en inglés). Esto permite como se puede observar en la parte inferior de la Figura 2.2 tener una firma espectral para cada píxel de la imagen. De esta manera es posible representar espectralmente los diferentes materiales presentes en la escena.

Las HSI, con su mayor resolución espectral, son capaces de detectar variaciones sutiles en la cubierta terrestre y sus cambios a lo largo del tiempo, lo que permite un análisis detallado de las superficie terrestre y de los diferentes materiales presentes en la escena. Las constelaciones que capturan imágenes hiperespectrales suelen capturar más de 100 bandas espectrales en un rango que va desde el ultravioleta (UV), pasando por el rango visible, el infrarrojo cercano (NIR), hasta el infrarrojo de onda larga (LWIR). El rango de cada uno de estos espectros se puede observar en la Figura 2.3. Gracias a esto las HSI permiten por ejemplo, una evaluación más precisa y oportuna del estado fisiológico de los cultivos agrícolas (Gonzalez-Dugo et al., 2015). Además de las aplicaciones agrícolas, las HSI se han utilizado en diversas aplicaciones, como la cartografía mineralógica de la

superficie terrestre (Clark and Swayze, 1995), la arqueología (Liang, 2011), el control de los recursos hídricos (Govender et al., 2009), el diagnóstico médico (Carrasco et al., 2003), y el control de calidad de los alimentos (Feng and Sun, 2012), entre otros.

Los sensores que permiten capturar imágenes hiperespectrales se denominan espectrómetros (Eismann, 2012), y suelen estar en plataformas como satélites, aviones, UAVs, y en plataformas de corto alcance, lo que permite adquirir imágenes con diferentes resoluciones espaciales y temporales (Lu et al., 2020). Dado al gran auge de los UAVs en la últimas dos décadas y al desarrollo de sensores hiperespectrales más ligeros y económicos, los investigadores han experimentado con el montaje de sensores hiperespectrales en UAVs para adquirir HSI de alta resolución espacial (Capolupo et al., 2015), permitiendo múltiples aplicaciones, como la estimación de clorofila en vegetaciones (Fenghua et al., 2017), la estimación de contenido de nitrógeno (Akhtman et al., 2017), la estimación de contenido de agua (Izzo et al., 2019), la clasificación de vegetación (Scherrer et al., 2019), la detección de enfermedades en cultivos (Bohnenkamp et al., 2019), la clasificación de cartografía batimétrica de ríos (Kwon et al., 2023), la recuperación de la calidad del agua (Lu et al., 2021), y la medición de concentración de sedimentos en canales (Kwon et al., 2022), entre otros.

### **2.3.1. Imágenes hiperespectrales en la caracterización de los cuerpos de agua**

Las imágenes hiperespectrales se han utilizado para investigar la reflectividad y los parámetros de calidad del agua desde la década de los noventa (Lee et al., 1999; Zarco-Tejada et al., 2012; Wang et al., 2016; Lu et al., 2021; Kwon et al., 2022, 2023). La reflectividad del agua está influenciada por su pureza y la presencia de partículas en suspensión. La respuesta espectral del agua varía a lo largo del espectro electromagnético, presentando una reflectividad muy baja en el espectro visible y prácticamente nula en el infrarrojo. La mayor reflectividad se produce en el azul y disminuye hacia el infrarrojo

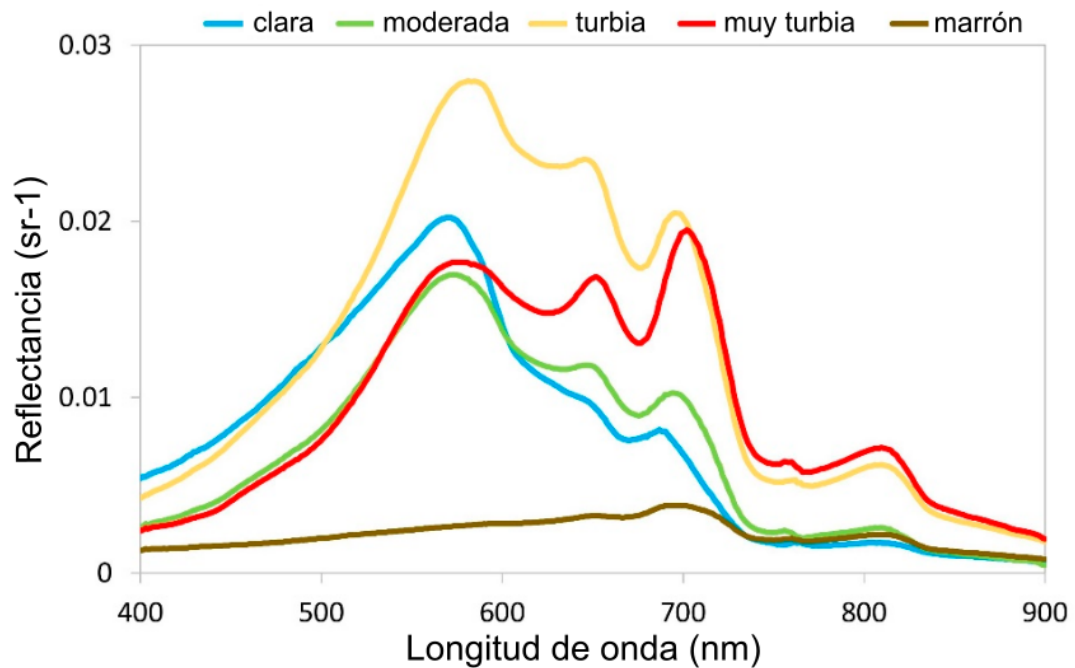


Figura 2.4: Ejemplo de espectro de reflectancia del agua para cinco clasificaciones ópticas (OWT) (Uudeberg et al., 2019).

cercano cuando no hay material en suspensión. La variabilidad del agua se detecta mejor en las longitudes de onda cortas (azul y verde), lo cual está relacionado con la profundidad, la concentración de materiales en suspensión y la rugosidad de la superficie. Además, los materiales del fondo, como la arena clara o la materia orgánica, también afectan la respuesta espectral, reduciendo la reflectancia a medida que aumenta la profundidad del agua (Chuvieco and Salinero, 1990).

La transparencia del agua se mide con un Disco de Secchi, y su profundidad es inversamente proporcional a la concentración de materia orgánica e inorgánica en el agua (Kirk, 2010; Matthews, 2011). Una clasificación óptica del tipo de agua (OWT) realizada por Uudeberg et al. (2019) dentro del rango espectral VNIR muestra cómo la reflectancia del agua varía en función de la presencia de sustancias ópticamente activas, sedimentos, floraciones y material orgánico disuelto en el agua. La Figura 2.4 muestra los resultados de referencia obtenidos en dicho estudio, permitiendo clasificar aguas interiores y costeras

en cinco OWT basadas en las características del espectro de reflectancia. Los resultados de este estudio y muchos otros disponibles ([Matthews, 2011](#); [Zeng et al., 2017](#); [Ma et al., 2019](#); [Borkowski and Młynarczyk, 2019](#)) muestran que la reflectividad del agua tiende a disminuir en la longitud de onda azul y presenta un máximo en las longitudes de onda verde y amarillo. En el infrarrojo cercano, la reflectividad es baja en aguas claras pero aumenta con la concentración de partículas en suspensión. Esto confirma por qué el rango espectral que suele utilizarse para realizar estudios y caracterización en cuerpos de agua es el VNIR, comprendido entre los 400 y 1000 nm ([Figura 2.3](#)), dado que es el rango espectral donde se pueden captar las mayores variaciones de reflectancia en los cuerpos de agua.

## 2.4. Fusión pancromática

Los sistemas de teledetección óptica permiten capturar diferentes rangos espectrales, clasificándose en rojo-verde-azul (RGB) ([Jin et al., 2017](#)), multiespectrales (MS) ([Brook et al., 2020](#)), hiperespectrales (HS) ([Camino et al., 2018](#)) y térmicos ([Bian et al., 2019](#)). En el diseño de estos sensores, existe un limitante crítico entre la resolución espacial, la resolución espectral y la relación señal-ruido (SNR), principalmente debido a la cantidad limitada de energía incidente ([Loncan et al., 2015](#)). Por consiguiente, los sensores ópticos pueden proporcionar datos con alta resolución espacial pero con un número limitado de bandas espectrales, como la imagen pancromática (IPAN) del satélite PRISMA ([PRISMA, 2019](#)) de 5 m por píxel, o con una alta resolución espectral pero baja resolución espacial, como en el caso de las imágenes multiespectrales (MSI) con más de diez bandas (por ejemplo, las constelaciones Landsat-8 ([Landsat-8, 2023](#)), MODIS ([MODIS, 2024](#)), Sentinel-3 ([Sentinel-3, 2023](#)), con resoluciones de 30 m, 250 m y 500 m por píxel respectivamente), o las imágenes hiperespectrales (HSI) con cientos de bandas, como la constelación PRISMA ([PRISMA, 2019](#)) con una resolución de 30 m por píxel.

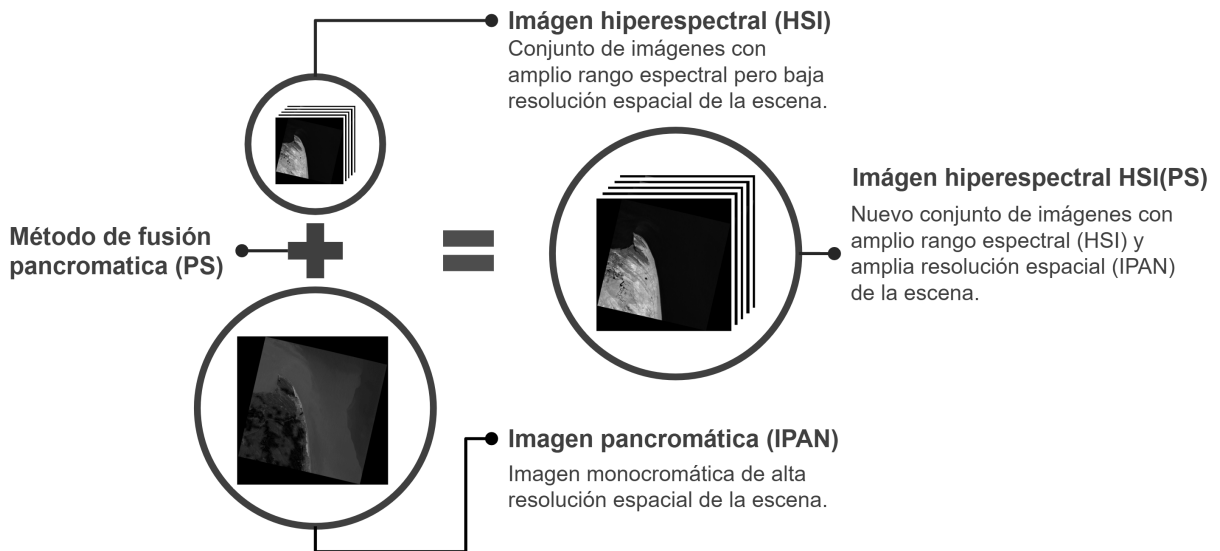


Figura 2.5: Esquema de la metodología de fusión pancromática a partir de una imagen hiperespectral y pancromática.

En el procesamiento de imágenes, se han propuesto diversos métodos para mejorar la resolución, desde diferentes técnicas de interpolación hasta métodos de fusión de imágenes, con el objetivo de producir imágenes de mayor resolución con la menor distorsión posible. Basándose en esto, es posible realizar fusiones entre imágenes satelitales. Según [Swathika and Sharmila \(2018\)](#), se requiere de una IPAN de mayor resolución para extraer su información espacial y fusionarla con el conjunto de bandas espectrales asociadas a las MSI. Esta técnica se conoce como fusión pancromática o pansharpening (PS). Su propósito fundamental radica en mejorar la resolución de las MSI mediante la fusión de la IPAN con el conjunto de bandas espectrales, preservando al mismo tiempo sus características y rango espectral. Sin embargo, el desafío del PS radica en encontrar métodos que ofrezcan un rendimiento óptimo en todo el espectro de las imágenes, el cual no está completamente representado por los datos pancromáticos ([Loncan et al., 2015](#)). En la Figura 2.5 se presenta un esquema de la metodología que describe la fusión pancromática.

Aunque la mayoría de los métodos de PS han sido desarrollados para fusionar datos pancromáticos con MSI, en la actualidad se han expandido para incluir HSI, dada la

relevancia y disponibilidad de estas últimas, como las de la constelación PRISMA. Diversos estudios han abordado diferentes métodos de pansharpening ([Chen, 2006](#); [Thomas et al., 2008](#); [Vivone et al., 2015](#)), los cuales se basan principalmente en transformaciones aritméticas, sustitución de componentes, análisis de multiresolución, enfoques bayesianos y métodos basados en aprendizaje profundo. Dentro de estos métodos, el de sustitución por Análisis de Componentes Principales (PCA), que es la base de varios métodos híbridos, ha presentado resultados sobresalientes en MSI y HSI ([Sarp, 2014](#); [Loncan et al., 2015](#); [Kremezi et al., 2021](#)), logrando un equilibrio entre obtener imágenes con una baja distorsión espacial, bajos niveles de SNR y manteniendo las características espectrales del conjunto de bandas.

#### **2.4.1. Pansharpening mediante análisis de componentes principales**

El método de pansharpening mediante Análisis de Componentes Principales (PS-PCA), se basa en el algoritmo al que atribuye su nombre, el cual mediante una rotación de los datos (transformación lineal), da lugar a los componentes principales (PC) ([Loncan et al., 2015](#)) cuyo número de componentes es igual al número de bandas espectrales. El principio base del PS-PCA subyace en que la información espacial que es compartida por todos los canales se concentra en la primera componente principal PC1, mientras que la información espectral en las demás PC. El método de PS-PCA se basa en cinco pasos (ver también [Martinez Vargas and Vitale \(2024\)](#)). Primero, el conjunto de imágenes hiperespectrales (HSI) se debe interpolar a las dimensiones de la imagen pancromática (IPAN). Segundo, con el conjunto HSI interpolado se obtienen tantos PC como bandas HS existan. Tercero, se iguala el histograma de la IPAN al de la PC1, obteniendo una imagen pseudo-pancromática. Cuarto, Se sustituye la PC1 por la imagen pseudopancromática. Quinto, Se aplica la operación inversa de PCA a todos los componentes para obtener los datos espectrales fusionados. Matemáticamente el método de fusión PCA puede describirse a

través de las ecuaciones (2.1) y (2.2) (Vivone et al., 2015), donde los vectores  $w$  y  $g$  son los coeficientes que se derivan del procedimiento PCA aplicado al conjunto HSI.

$$\hat{Y}^k = \hat{X}_H^k + g_k(P - O_l), \quad (2.1)$$

para  $k = 1, \dots, m\lambda$  donde  $\hat{Y}^k$  relaciona la banda  $k$  a ser estimada a una mayor resolución,  $\hat{X}_H$  representa las HSI interpoladas a la escala de la IPAN,  $g = [g_1, \dots, g_m\lambda]^T$  es el vector que contiene las ganancias de inyección,  $\lambda$  denota el número de bandas de la imagen HSI y  $m$  el número de píxeles de la imagen  $\hat{Y}^k$ . El termino  $O_l$  se define como:

$$O_l = \sum_{i=1}^{m_x} w_i \hat{X}_H^i, \quad (2.2)$$

donde los pesos  $w = [w_1, \dots, w_i, \dots, w_m\lambda]^T$  miden el solapamiento espectral entre las bandas espectrales y la IPAN (Tu et al., 2004; Chen, 2006).

Una vez obtenido el conjunto  $\hat{X}$  se realiza una verificación de rango a cada valor digital del conjunto de datos, el cual debe estar dentro de la resolución en bits del conjunto HSI original. Aquellos valores que estén fuera de rango serán asignados al valor mínimo o máximo de la resolución en bits según corresponda. Por ejemplo, para una resolución de 16 bits el rango esta entre 0 y 65535.

## 2.5. Modelos de aprendizaje de máquina implementados

### 2.5.1. Bosques aleatorios

El modelo de bosques aleatorios, también conocido como Random Forest (RF), es una técnica avanzada y a menudo utilizada en el ámbito del aprendizaje automático. Este enfoque se fundamenta en la construcción de múltiples árboles de decisión (DTs) durante



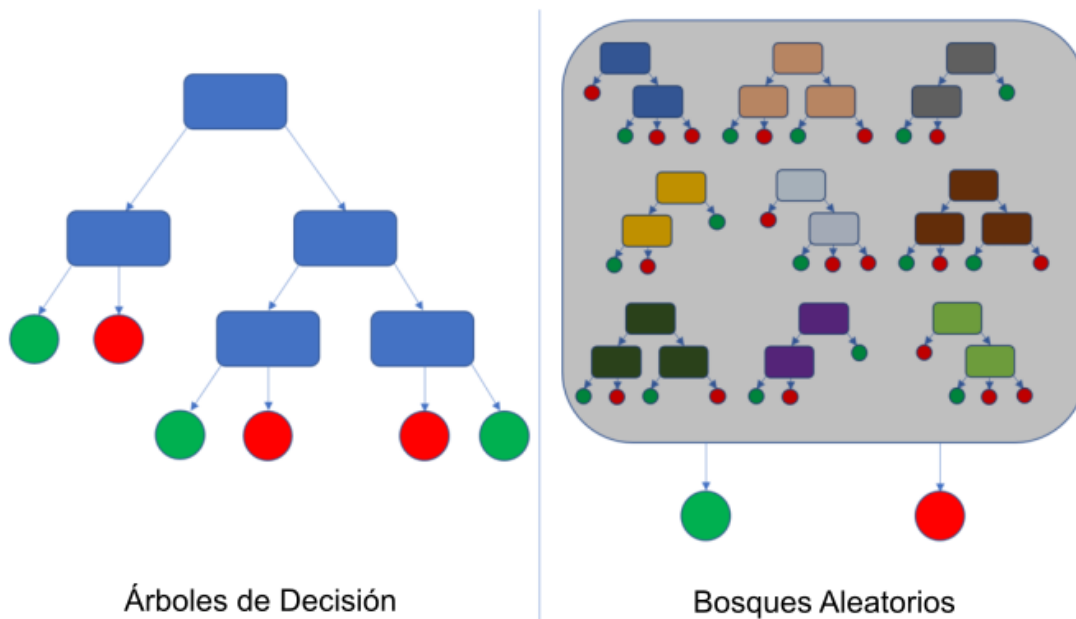


Figura 2.6: Comparación entre árboles de decisión y bosques aleatorios. De Wikimedia Commons, el repositorio multimedia libre. Autor: Jeremybeauchamp (CC-BY-SA-4.0).

el proceso de entrenamiento y la combinación de sus resultados con el fin de incrementar la precisión y robustez del modelo. Dado esto, analizaremos los modelos basados en los DTs que constituyen los componentes básicos del algoritmo RF. Los modelos basados en los DTs consisten en una serie de reglas que operan sobre un conjunto de variables, lo que permite estimar o predecir el valor de otra variable. Para lograr esto, se establecen reglas que se aplican simultáneamente a un predictor y se dividen los datos de entrenamiento en dos grupos. Esto da como resultado un nodo de toma de decisiones. La primera acción sobre el conjunto de datos se conoce como nodo raíz y las particiones creadas dan lugar a las distintas ramas del árbol. Finalmente, el nodo hoja, que corresponde a un subconjunto de datos de entrada que está conectado a una categoría específica de datos de salida, es el resultado final de las ramas (Schonlau and Zou, 2020). En la Figura 2.6 puede verse un ejemplo, donde los nodos en color rojo y verde se asocian con un tipo de fruto. Esto indica el fin de la clasificación, si se ha llegado al nodo rojo el algoritmo indica que la fruta es una cereza. Dependiendo de cómo se establezcan los criterios de partición y parada,

los árboles de decisión pueden diseñarse tanto para tareas de clasificación como de de regresión. Existen diferentes algoritmos que permiten al aproximación de un árbol de decisión óptimo, dentro de los mas destacados se tienen AID, CHAID, y CART que es uno de los mas usados (Rigatti, 2017). CART usa la impureza Gini como métrica para determinar que tan buena resulta una determinada decisión en la construcción de un nodo de decisión. En el caso de los DTs para problemas de regresión la métrica para crear nodos de decisión suele ser el error cuadrático medio (MSE).

Uno de los principales problemas de los árboles de decisión es que suelen conducir al sobreajuste de los datos, lo que o provoca una baja precisión del modelo, debido a la falta de generalización (Schonlau and Zou, 2020). Además, pueden ser muy sensibles a pequeños cambios en los datos utilizados en el entrenamiento, generando inestabilidad ante una varianza elevada. Para combatir este problema Breiman (2001) estableció las bases fundamentales del modelo de bosques aleatorios. Cuyo concepto fundamental es la agregación de predicciones de varios árboles, donde el resultado es el promedio de las predicciones de muchos árboles individuales. En lugar de la muestra original, los árboles individuales se obtienen a partir de un conjunto de muestras bootstrap (Bernard et al., 2009). Es decir, cada modelo se entrena con la misma cantidad de datos, solo que algunos de los datos originales están repetidos mas de una vez y otros no están. Adicionalmente, al construir los árboles, cada árbol se entrena con un subconjunto de predictores diferente, que son elegidos aleatoriamente sin repetición. Esto permite reducir el riesgo de sobreajuste y mejorar la capacidad predictiva general, gracias a que se incrementa la independencia de los árboles y por ende sus errores, lo cual puede conducir a una mayor reducción en el error de clasificación o regresión según sea el caso (Boateng et al., 2020).

En la Figura 2.6 puede observarse una comparación entre un árbol de decisión y los bosques aleatorios. Este enfoque ha demostrado ser efectivo en una variedad de aplicaciones, como la clasificación, la regresión y en tareas de aprendizaje supervisado en general.

La fortaleza del modelo radica en su capacidad para manejar conjuntos de datos grandes y complejos, así como para lidiar con características irrelevantes o ruidosas.

Investigaciones recientes han mostrado la aplicabilidad del modelo de bosques aleatorios en diversas áreas. Por ejemplo, [Belgiu and Drăguț \(2016\)](#) muestran diversas aplicaciones de RF en teledetección, [Sylvester et al. \(2017\)](#) uso RF para la selección de características a una escala fina de poblaciones genéticas, [Tyralis et al. \(2019\)](#) exploró sus aplicaciones en los recursos hídricos, [Yao et al. \(2020\)](#) empleó RF para la predicción de granizo en la península de Shandong, y [Xiao et al. \(2023\)](#) usó RF para la generación de mapas de espesor del suelo mediante un enfoque geomorfológico-empírico.

En conclusión, el modelo de bosques aleatorios se destaca por su robustez y estabilidad, proporcionando un rendimiento consistente y resistente al sobreajuste. Su capacidad para manejar conjuntos de datos complejos sin preselección de características lo hace eficiente en aplicaciones del mundo real, así como la evaluación de la importancia de las características facilita la interpretabilidad de los modelos.

### 2.5.2. Máquinas de soporte vectorial

El modelo de Máquinas de Soporte Vectorial, también conocido como Support Vector Machine (SVM), es una técnica ampliamente utilizada en el campo del aprendizaje automático. Las SVM son conocidas por su capacidad para manejar tanto problemas de clasificación como de regresión, y han demostrado ser efectivas en una variedad de aplicaciones debido a su capacidad para encontrar hiperplanos que separan de manera óptima las clases o se ajustan de manera óptima a los datos de entrenamiento.

En las SVM, el objetivo principal es encontrar el hiperplano ( $w * x - b = 0$ ) que maximiza la margen de separación entre las clases o que mejor se ajusta a los datos de regresión (donde  $w$  es un vector de pesos,  $x$  es el vector de entrada y  $b$  es el sesgo). Los vectores de soporte ( $w * x - b = \pm 1$ ), que son los puntos de datos más cercanos al hiperplano, juegan un papel crucial en la determinación de la ubicación y orientación del hiperplano




Figura 2.7: Máquinas de soporte vectorial (SVM): Hiperplano de margen máximo y márgenes para las SVM entrenadas con dos clases. Las muestras en los márgenes se denominan vectores de soporte ( $w$  es un vector de pesos,  $x$  es el vector de entrada y  $b$  es el sesgo). De Wikimedia Commons, el repositorio multimedia libre. Autor: Larhman (CC-BY-SA-4.0).

(Figura 2.7). La función de pérdida en las SVM penaliza los errores de clasificación o regresión y busca minimizarlos, garantizando al mismo tiempo la maximización del margen. Varias investigaciones han contribuido a la comprensión y mejora de las SVM en los últimos años. Por ejemplo, [Vapnik \(1995\)](#) introdujo los conceptos fundamentales de las máquinas de soporte vectorial, estableciendo las bases teóricas del algoritmo. [Schölkopf and Smola \(2002\)](#) proporcionaron una visión más detallada de las SVM, destacando su capacidad para manejar datos no lineales a través una técnica de ampliación del espacio de datos, denominada truco del kernel (o kernel trick), donde el kernel es una función matemática elegida especialmente para facilitar la separación de los datos en el espacio de

datos original. Además, investigaciones recientes han explorado extensiones y aplicaciones específicas de las SVM. En el trabajo de [Hsu et al. \(2003\)](#), se presentan estrategias para mejorar la eficiencia computacional de las SVM. Por otro lado, [Wang et al. \(2023\)](#) proponen un enfoque para las SVM que permite la selección automática de los hiperparámetros del modelo.

Las ventajas del uso de las SVM incluyen su capacidad para manejar espacios de datos de alta dimensión, su eficacia en conjuntos de datos pequeños y su flexibilidad para abordar problemas lineales y no lineales. Sin embargo, las SVM pueden enfrentar desafíos en términos de interpretación de modelos y escalabilidad para grandes conjuntos de datos. En resumen, este modelo ha demostrado ser una herramienta versátil y efectiva en el ámbito del aprendizaje automático, y las investigaciones continuas siguen mejorando su rendimiento y aplicabilidad en diversas áreas.

## **2.6. Métodos de interpolación para generar mapas batimétricos**

Cuando se tienen mediciones batimétricas de un cuerpo de agua, el método convencional que suele utilizarse para generar mapas a partir de estos puntos es la interpolación. Este proceso, a través de métodos matemáticos, puede encontrar o definir valores desconocidos en puntos de interés a partir de los valores conocidos en puntos circundantes. El método comúnmente más conocido y empleado para realizar interpolación de datos es la interpolación lineal, donde, a partir de rectas, se busca generar conexiones entre los puntos circundantes y así encontrar los valores intermedios entre los puntos. En la interpolación lineal, los valores intermedios se determinan asumiendo que el cambio entre dos puntos conocidos es lineal, es decir, sigue una línea recta. Esto puede ser útil para generar una estimación rápida y sencilla de la batimetría, pero puede no capturar todas




Figura 2.8: Comparación de métodos de interpolación: (a) Interpolación lineal. (b) IDW. (c) Kriging. De Wikimedia Commons, el repositorio multimedia libre. Autor: Helena Mitsova (CC-BY-3.0).

las variaciones reales del fondo marino, especialmente en áreas donde las profundidades cambian de manera no lineal (ver Figura 2.8a).

Estudios recientes (Ibrahim et al., 2022; Jamali et al., 2023; Boumpoulis et al., 2023) muestran que los métodos más utilizados para generar reconstrucciones topobatimétricas y batimétricas a partir de mediciones dispersas son Kriging, IDW (Inverse Distance Weighting) (ver Figura 2.8b,c), Spline y TIN (Triangulated Irregular Network). Entre estos, el método Kriging es el más popular y usado debido a que es una técnica avanzada que no solo considera la distancia entre los puntos, sino que también tiene en cuenta la estructura espacial de los datos. Esto incluye la variabilidad y correlación entre los puntos, lo que le permite realizar estimaciones más precisas. Kriging utiliza un modelo de semi-variograma para capturar la dependencia espacial y hacer predicciones en ubicaciones no muestreadas, proporcionando no solo una estimación de la profundidad, sino también una medida de la incertidumbre asociada a dicha estimación. En comparación, otros métodos como IDW, Spline y TIN pueden ser más simples de implementar, pero no suelen ofrecer el mismo nivel de precisión ni la capacidad de manejar variabilidad espacial compleja como lo hace Kriging (Boumpoulis et al., 2023). Si bien estos métodos de interpolación son los más utilizados en estudios batimétricos su uso se puede extender a mediciones georeferenciadas de variables de calidad del agua como temperatura, sólidos en suspensión, concentración de carbono orgánico, entre otros.

## Capítulo 3

# Desarrollo de tecnologías: Plataforma de monitoreo y adquisición de datos multiparamétrica de código abierto y bajo costo

La monitorización del agua enfrenta retos relacionados con la infraestructura, la protección, los recursos financieros, los recursos humanos y las políticas científicas y de innovación. En este capítulo, presentamos el desarrollo de la segunda versión de EMAC-USV un vehículo de superficie no tripulado perteneciente a la familia de Estaciones de Monitoreo Ambiental y Costero (EMAC) en el Instituto Argentino de Oceanografía (IADOC-CONICET, Bahía Blanca, Argentina). Sus características principales son modularidad, bajo costo, arquitectura abierta y pequeño tamaño. EMAC-USV v2.0 permite la monitorización de parámetros batimétricos y de calidad del agua en escenarios hídricos complejos.

Mientras que la primera versión solo permitía mediciones de batimetría a través de una ecosonda Garmin, esta segunda versión permite la medición de múltiples parámetros de calidad del agua como temperatura, concentración de sólidos en suspensión, concentración de carbono orgánico, entre otros. Además de realizar mediciones de batimetría georreferenciada mediante un Ping Sonar y un registrador de datos flexible con monitoreo remoto integrado. EMAC-USV v2.0 también está equipado con un sistema de doble propulsión que facilita la maniobrabilidad en espacios reducidos y de difícil acceso, permitiéndole girar sobre su propio eje.

Esta nueva versión del vehículo EMAC-USV v2.0 y las metodologías de modelos batimétricos hiperespectrales propuestas en el capítulo 4 conforman un nuevo sistema de monitoreo, adquisición y procesamiento de datos georreferenciados para escenarios hídricos. EMAC-USV v2.0 permitirá, en futuras campañas de adquisición de datos, validar los modelos batimétricos obtenidos en el capítulo 4.2, donde se tomaron datos de profundidad procedentes de una carta náutica. Además, permitirá relevar nuevas mediciones con las cuales se generarán modelos batimétricos actualizados basados en imágenes hiperespectrales. Incluso, se podrán integrar parámetros de calidad del agua, lo cual permitirá caracterizar de manera más completa los escenarios hídricos de las áreas de estudio de interés.

En este apartado se expondrán las condiciones de diseño y desarrollo de EMAC-USV v2.0 (ver también [Martinez Vargas et al. \(2023a,b\)](#)). Se incluye una descripción detallada de cada parte de la plataforma, así como de los módulos electrónicos y su funcionamiento. Una contribución significativa de este desarrollo es el diseño y desarrollo de una Unidad de Adquisición de Datos (UAD) flexible y de bajo costo. La UAD cuenta con un firmware personalizado de código abierto que puede replicarse fácilmente y permite la operación de varios sensores tanto de manufactura local como comercial. Para validar el funcionamiento, operación, y registro de datos del vehículo, se monitorearon la batimetría y los parámetros de calidad del agua (es decir, temperatura, concentración de



sólidos en suspensión (CSS), y concentración de carbono orgánico (CCO)) en dos escenarios acuáticos complejos. El primero corresponde a pequeñas y poco profundas lagunas de estabilización de residuos (provincia de Buenos Aires, Argentina). El segundo, en una porción del canal principal de marea del puerto de Bahía Blanca (estuario de Bahía Blanca, Argentina). EMAC-USV v2.0 es el resultado de un diseño equilibrado que mantiene un balance entre el rendimiento, las comunicaciones, y la capacidad de carga útil, entre otros.

### 3.1. EMAC-USV versión inicial


La primera versión de EMAC-USV (ver Figura 3.1) fue desarrollada en el IADOC-CONICET por el Dr. Ing. Alejandro Vitale en el año 2014, utilizando la arquitectura abierta ArduPilot (<https://ardupilot.org/>). Este vehículo permitía realizar estudios de batimetría y podía ser operado de forma manual o automática mediante una ruta de navegación programada. EMAC-USV estaba equipado con un sonar Garmin Echo 100 de 200 kHz, que permitía registrar mediciones batimétricas georreferenciadas. El software Mission Planner gestionaba la navegación y el monitoreo del vehículo mediante la marcación de waypoints dentro de un área de interés, lo que le permitía seguir una ruta programada. Además, el vehículo podía ser operado de forma manual mediante un control remoto vía RC. Esta primera versión de EMAC-USV proporcionó una plataforma inicial para la adquisición de datos georreferenciados en entornos acuáticos, facilitando la investigación y monitoreo de datos batimétricos en diversos escenarios hídricos. Los primeros estudios batimétricos se realizaron en lagos poco profundos (Alfonso et al., 2018; Seitz et al., 2020) y en canales de marea (Genchi et al., 2020; Martinez Vargas et al., 2021a,b).

No obstante, el vehículo tenía limitaciones, ya que no contaba con una unidad de adquisición de datos que le permitiera registrar mediante sensores otras mediciones, como temperatura, concentración de sólidos en suspensión, clorofila, entre otros, que serían de gran utilidad para caracterizar escenarios hídricos. Además, el sistema de propulsión,

basado en un único motor de propulsión y un sistema de dirección con doble timón (Figura 3.1b), solo le permitía realizar giros con un radio máximo de 45 grados, lo cual limitaba su operación en áreas reducidas o con presencia de obstáculos.



(a)



(b)

Figura 3.1: Primera versión del vehículo de superficie no tripulado (USV) perteneciente a la familia de Estaciones de Monitoreo Ambiental y Costero (EMAC) en el IADOC-CONICET denominado EMAC-USV: (a) Vista exterior. (b) Sistema de propulsión basado en un único propulsor y un sistema de dirección de doble timón.

### 3.2. EMAC-USV v2.0

Partiendo de las limitaciones mencionadas previamente de la primera versión de EMAC-USV, se redefinieron las características de navegabilidad y se diseñó el sistema de sensado y monitoreo multiparamétrico a finales del año 2021. De la versión inicial se mantuvo únicamente el casco catamarán y el sistema de navegación automático ArduPilot 2.5.

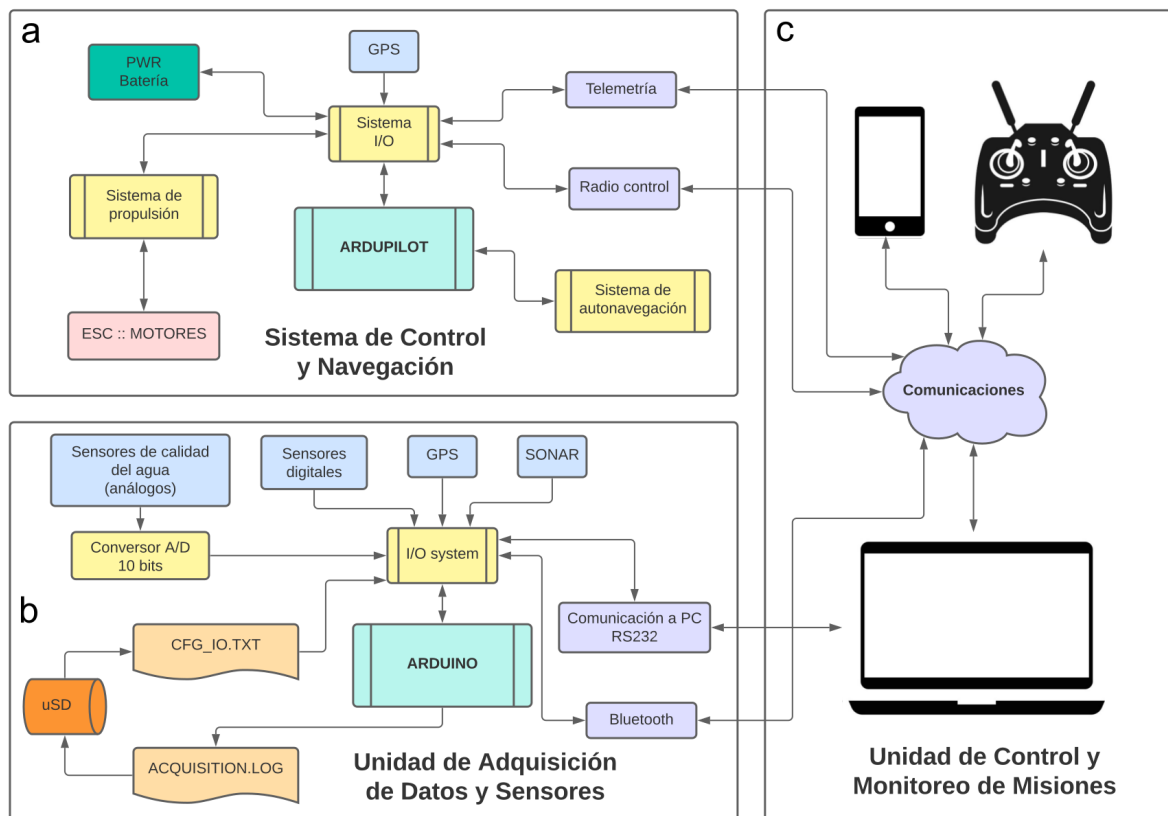


Figura 3.2: Diagrama que describe la arquitectura software/hardware de EMAC-USV v2.0: (a) Unidad de Control y Comunicaciones. (b) Unidad de Adquisición de Datos y Sensores. (c) Unidad de Control y Monitoreo de Misiones.

Un equipo de investigadores del IADO-CONICET creó y desarrolló la mayoría de las partes electrónicas y mecánicas de EMAC-USV v2.0. La Figura 3.2 muestra en un diagrama de la arquitectura de hardware y software de la plataforma propuesta. La Tabla 3.1 muestra las especificaciones técnicas de EMAC-USV v2.0 y la Figura 3.3 muestra el diseño

renderizado. La plataforma, ha mejorado significativamente en los últimos años basándose principalmente en las limitaciones físicas y cinemáticas asociadas con las masas de agua complejas.

### 3.2.1. Estructura del vehículo y limitaciones de diseño

La embarcación es un casco catamarán con una estructura de  $1.30 \times 0.35 \times 0.30$  m (Figura 3.3). El diseño de la plataforma se basó en las limitaciones cinemáticas y físicas. Por ejemplo, se logró una mejor planitud con un bajo calado (aproximadamente 0.12 m, Figura 3.3b). El casco de fibra de vidrio y la resina epoxi mejoran la resistencia y la durabilidad (Hoge and Leach, 2016). Todos los módulos electrónicos, los sensores internos, y el banco de baterías se encuentran al interior del casco. En La Tabla 3.1 se muestra el peso de la plataforma con el banco de baterías estándar y su capacidad de carga útil. Un banco de dos baterías de polímero de litio (Li-Po) de 4S con 16000 mAh componen el sistema de suministro de energía.

EMAC-USV v2.0 tiene dos propulsores con hélices fijas horizontales (modelo T200) montados en la parte trasera del casco. Esto permite controlar independientemente la velocidad y dirección (Tabla 3.1, Figuras 3.3 e, f), logrando así desplazarse, retroceder, y girar en su mismo eje. Estos propulsores comerciales son de bajo costo y eficientes. El sistema de dos propulsores sustituye al de la versión inicial, que tenía un solo motor que accionaba una hélice en la parte posterior central del vehículo. El sistema de dirección de EMAC-USV estaba dado por un mecanismo de doble pala de timón que era controlado por un servomotor. Sin embargo, este sistema tenía un rango de acción de giro limitado (menos de 45 grados), lo que implicaba que el vehículo tardaba más en cambiar de dirección.

Con una carga plena de baterías en su configuración estándar, la plataforma puede durar alrededor de seis horas en operación. La Tabla 3.1 muestra las condiciones de trabajo ideales que se han estimado a partir de pruebas sobre el terreno. La velocidad del

viento inferior a  $12 \text{ ms}^{-1}$  y la altura de las olas inferior a 0.5 m son las condiciones más importantes.

**Tabla 3.1:** Especificaciones Técnicas de EMAC-USV v2.0

Especificación USV	Descripción
<b>Especificaciones técnicas</b>	
Dimensión	1 x 0.45 x 0.27 m
Peso del vehículo	8.6 kg
Carga útil	5 kg
Capacidad de almacenamiento	6.2 L
Velocidad crucero	$1.5 \text{ ms}^{-1}$
Banco de baterías estándar	4S -16000 mAh x 2
Banco de baterías extendido	4S -16000 mAh x 4
Tiempo de operación estándar	6H (con banco de baterías estándar)
Auto piloto	ArduPilot 2.5
Propulsores	T200-THRUSTER-R2-RP (@ 16V/24A - 390W) x 2
GPS	3DR uBlox (5 Hz tasa de actualización con modulo de compass digital HMC5883L)
Modem de radio telemetría	RDF900, 900Mhz, 1W, max. distancia: 2 a 5 km dependiendo de la altura de la estación base
Unidad de adquisición de datos	8 entradas análogas y 3 digitales, SD card de hasta 64 Gb conexión Bluetooth
Ecosonda	Ping Sonar
<b>Sensores de calidad del agua</b>	
Temperatura	Precisión: $\pm 0.1 \text{ }^{\circ}\text{C}$ ; Rango de medidas validado: -5 - 35 $^{\circ}\text{C}$
Sólidos en Suspensión	Precisión: $\pm 3 \%$ ; Rango de medidas validado: 0 - 200 NTU
<b>Condiciones de trabajo</b>	
Rango de temperatura del aire	-10 a 50 $^{\circ}\text{C}$
Tolerancia velocidad del viento	hasta $12 \text{ ms}^{-1}$
Tolerancia a altura de olas	hasta 0.5 m
Tolerancia al flujo de agua (dirección opuesta)	hasta $0.5 \text{ ms}^{-1}$
Radio mínimo de giro	2.5 m




Figura 3.3: Diseño renderizado de EMAC-USV v2.0 en diferentes vistas: (a,b) vistas laterales. (c) vista inferior. (d) vista superior. (e) vista posterior. (f) vista frontal.

### 3.2.2. Unidad de adquisición de datos

EMAC-USV v2.0 está equipado con unidades de detección que se despliegan principalmente en algunos lagos y en el mar argentino (Vitale et al., 2018; Estaciones de Monitoreo Ambiental Costero (EMAC), 2023). La Tabla 3.2 resume la descripción técnica de la unidad de adquisición de datos. La UAD es una caja compacta ( $0.20 \times 0.11 \times 0.03$  m) que fue impresa en 3D (Figura 3.4c). El dispositivo consta de una placa única de doble capa que incluye GPS, módulos de comunicación (Bluetooth y módem GPRS -opcional-), almacenamiento de datos, y gestión de energía (Tabla 3.2, Figuras 3.4a,b). La UAD también cuenta con un puerto de comunicación RS232 que permite la conexión a una PC para la depuración de datos y la actualización de firmware. La UAD tiene 3 entradas digitales y 8 entradas analógicas (resolución de 10 bits), que permite la integración de sensores comerciales con salidas analógicas o seriales. La UAD está basada en el microcontrolador Arduino ATmega2560. La implementación de la placa de circuito y el circuito esquemático se pueden ver en las Figuras 3.4b,c, respectivamente. Los datos se almacenan en una tarjeta micro-SD con capacidad máxima de hasta 64 Gb. En la Figura 3.5 Se muestra un diagrama de flujo que describe el funcionamiento de la UAD.

**Tabla 3.2:** Descripción de las principales características de la Unidad de Adquisición de Datos.

Especificación	Descripción
Temperatura de funcionamiento	-40 a 70 °C
Entradas analógicas	8 unidireccionales (expansible a 16)
Entradas digitales de contador de impulsos	1 (expansible a 2)
Puertos de comunicación	RS-232
Frecuencia máxima de muestreo	10 Hz (sin ecosonda), 3 Hz (con ecosonda)
GPS	U-blox NEO-6
Voltaje limite de entradas	+5V
ADC	10 bits
Rango de Alimentación	9 - 24 V
Tecnología de comunicación remota	Bluetooth/GPRS/RADIO
Rango de comunicaciones	Bluetooth: 50 m GPRS: 15 km (Depende del proveedor de servicio) RADIO: 2 a 5 km (Depende de la ubicación)
Corriente máxima de alimentación	3 A
Almacenamiento máximo	64 Gb



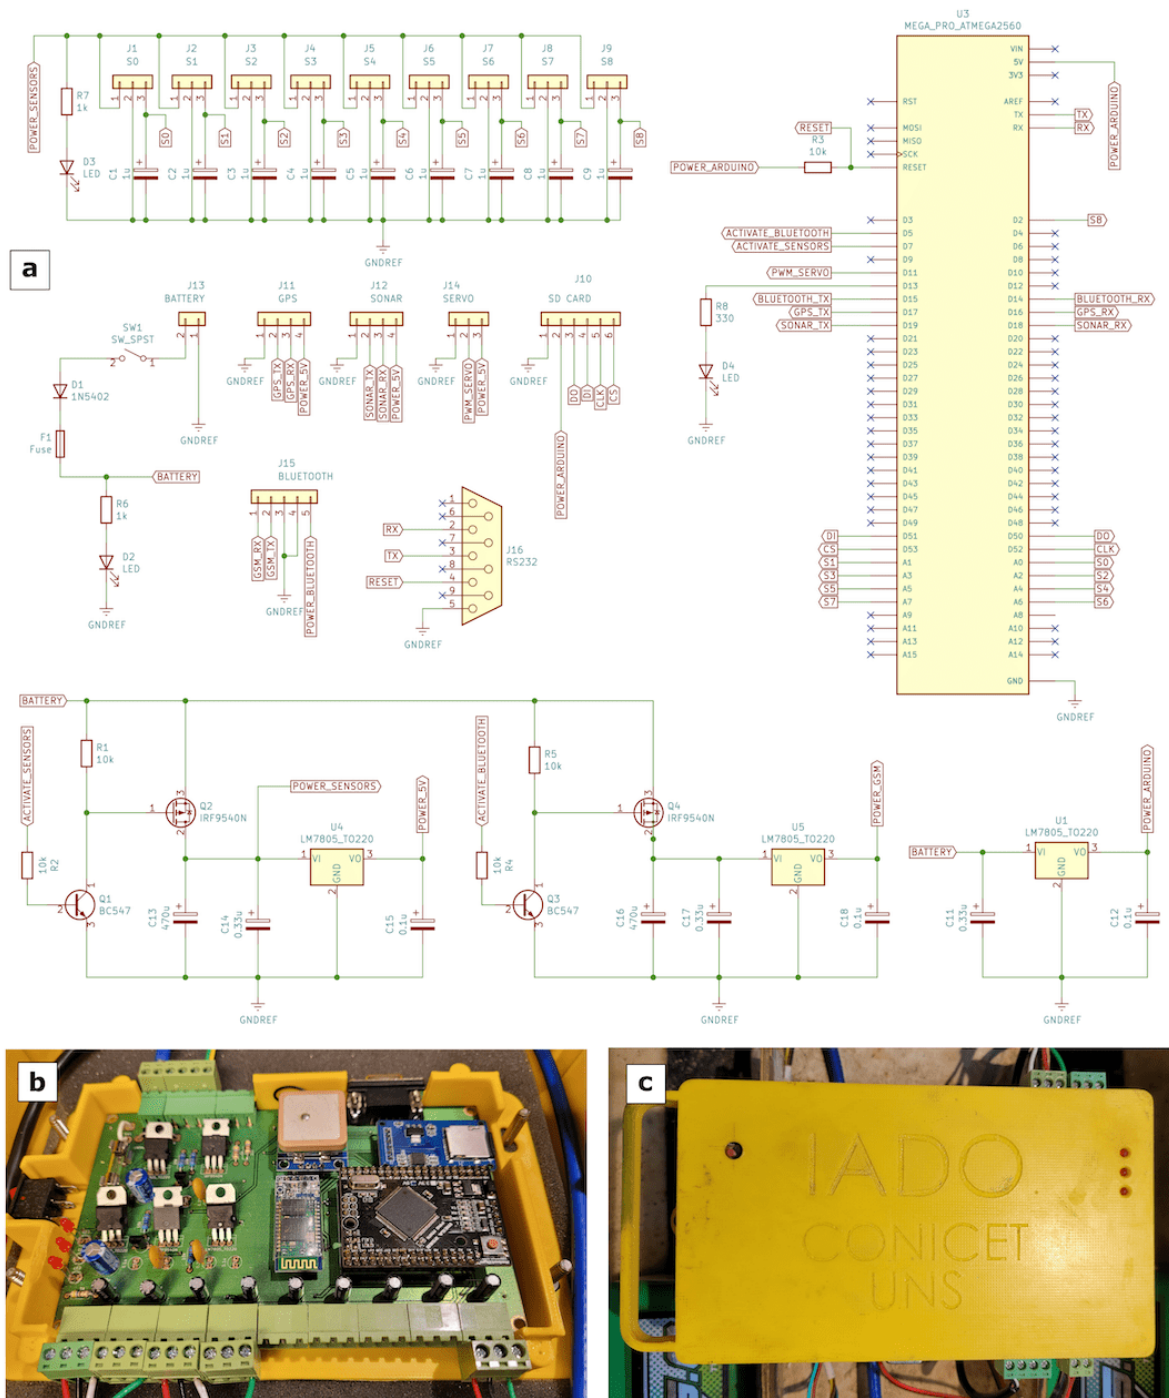


Figura 3.4: Unidad de Adquisición de Datos: (a) circuito esquemático. (b) implementación de la placa de circuito. (c) caja de la UAD.



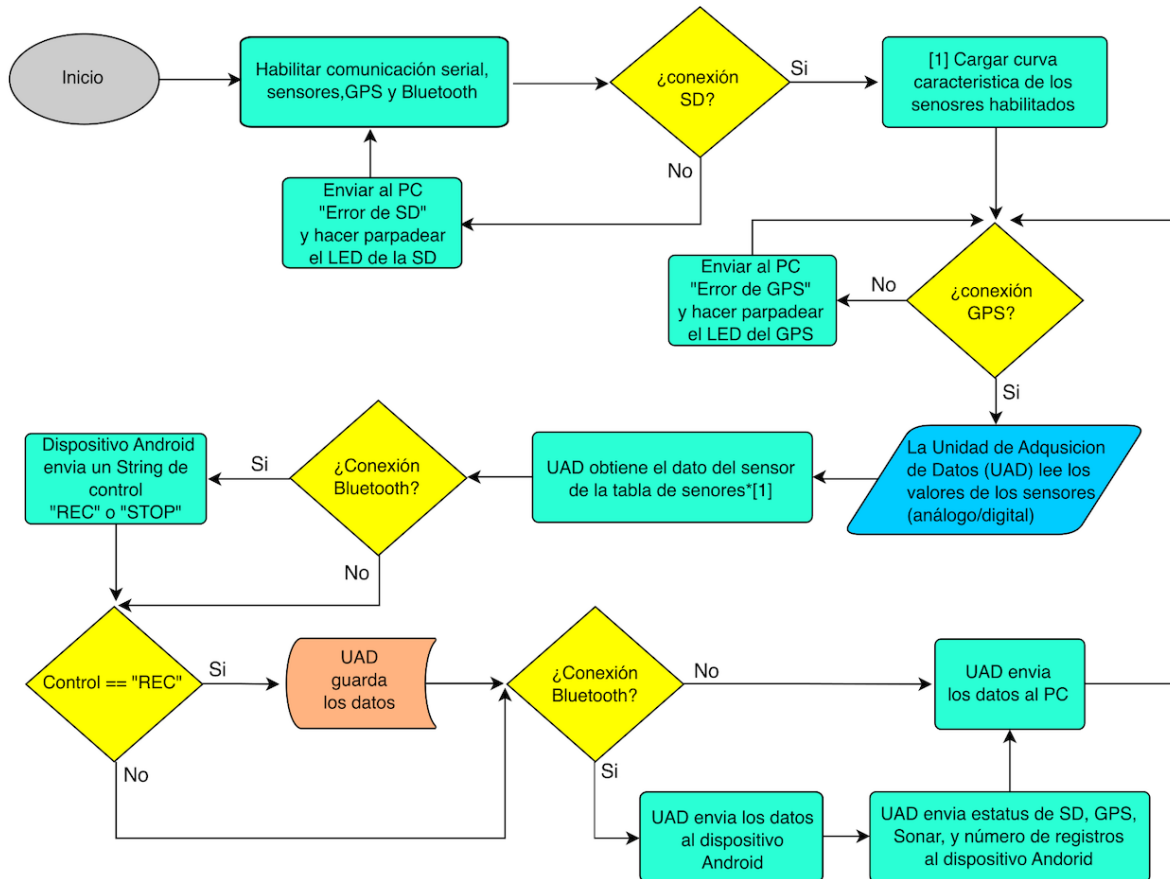


Figura 3.5: Diagrama de flujo que describe el funcionamiento de la Unidad de Adquisición de Datos.

### 3.2.3. Sensores

#### Ecosonda

EMAC-USV v2.0 está equipado con un sonar Ping ultrasónico compacto fabricado por Blue Robotics (Figura 3.6) a un precio competitivo. Estudios recientes han utilizado con éxito este dispositivo (Siregar et al., 2020; Ilyas et al., 2021; Potokar et al., 2022). Este sonar de haz único tiene un rango de alcance entre 0.5 - 50 m y un ancho de haz de 30 grados, con una frecuencia de 115 kHz. La precisión del sensor es del 0.5 %. Además de la profundidad, el sonar proporciona la respuesta de eco completa para realizar análisis de la columna de agua, así como del sedimento del fondo. Este último se programó para ser registrado por la UAD.



Figura 3.6: Ecosonda Ping Sonar monohaz (Blue Robotics).

#### Temperatura y concentración de sólidos en suspensión

Los sensores de temperatura y concentración de sólidos en suspensión, fueron diseñados por el Dr. Ing. Alejandro Vitale (IADO-CONICET), están integrados en un único elemento sensor. Los sensores de temperatura y CSS emplean un termistor NTCLE203E3103SB0 y un sensor óptico de retrodispersión, respectivamente (Vitale et al., 2018). En la Figu-

ra 3.7a y b puede observarse el circuito esquemático y una visualización 3D de los sensores de temperatura y CSS respectivamente. El cuerpo del sensor está construido en acero inoxidable y el cabezal es una pieza impresa en 3D. El sensor CSS utiliza un microcontrolador Microchip PIC12F675 para generar el pulso infrarrojo de 10 kHz OPB730F (sensor de objetos reflectantes). Para la salida analógica, la señal de retrodispersión se amplifica y procesa mediante un circuito rectificador de precisión, con tecnología de circuito integrado (TL082) (Vitale et al., 2018). La precisión es de  $\pm 0,1^{\circ}\text{C}$  (temperatura) y  $\pm 3\%$  (CSS); el tiempo de respuesta del sensor es inferior a 1 s.

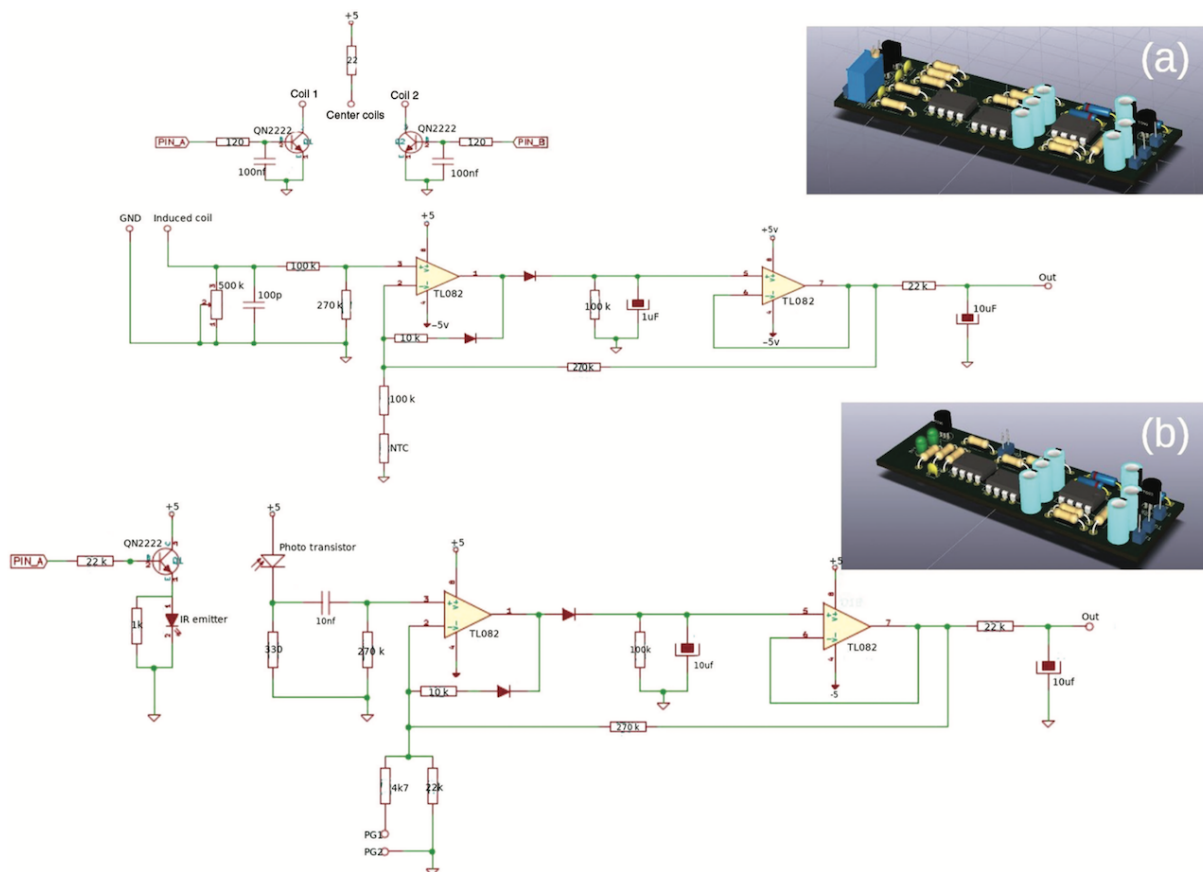


Figura 3.7: Sensores: (a) Temperatura. (b) Concentración de Sólidos en Suspensión.

### Concentración de carbono orgánico

EMAC-USV v2.0 esta también equipado con un sensor de concentración de carbono orgánico (modelo C-FLUOR) fabricado por Turner Designs (Figura 3.8). El sensor de CCO mide la fluorescencia in situ mediante una longitud de onda única con una señal de salida analógica de 0 a 5 V. Este sensor utiliza una excitación azul que trabaja de 0 a 200 ppb. El tiempo de respuesta del sensor es inferior a 1 s.



Figura 3.8: Sensor de Concentración de carbono orgánico (Turner Designs).

### 3.2.4. Unidad de control y comunicaciones

EMAC-USV v2.0 mantiene la misma Unidad de Control y Comunicaciones (UCC) que su versión anterior. En la Figura 3.9 puede observarse el esquema general de la UCC que operan de forma conjunta. El sistema de piloto automático IMU utiliza una placa Ardupilot Mega (APM), que permite la navegación autónoma (Figura 3.9b). El módulo APM envía una señal de potencia a dos propulsores (Figura 3.9a), lo que permite que el vehículo se mueva en todas las direcciones.

La telemetría bidireccional RDF900+ a 900 MHz y el radiocontrol de frecuencia a 2,4 GHz con un mínimo de 4 canales son los dos modos utilizados para la comunicación inalámbrica entre el operador y el vehículo (Figura 3.9b y c). Utilizando los módulos

inalámbricos de telemetría bidireccional, la plataforma rastrea una misión a partir de waypoints preprogramados en el software libre Mission Planner. EMAC-USV v2.0 obtiene la geolocalización del vehículo utilizando el módulo GPS 3DR de ublox LEA-6, que tiene una brújula de alta precisión (Figura 3.9b).

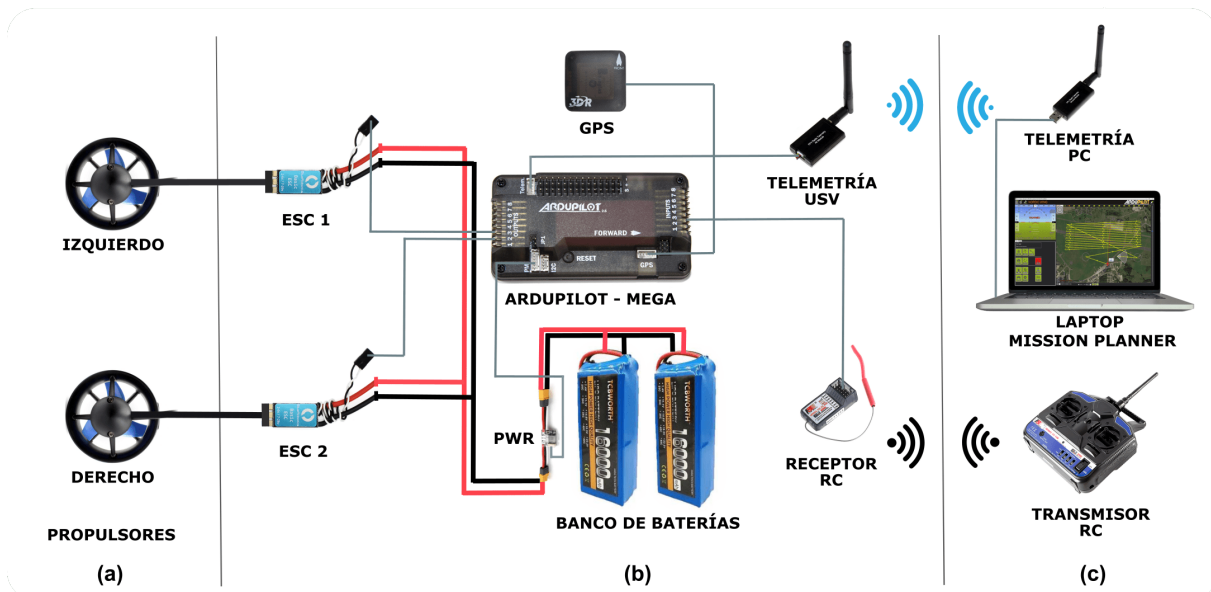


Figura 3.9: Arquitectura de la Unidad de Control y Comunicaciones de EMAC-USV-v2.0.

### 3.2.5. Unidad de control y monitoreo de misiones

#### EMAC Monitor

EMAC Monitor es una aplicación móvil desarrollada por el grupo de investigadores del IADO-CONICET para EMAC-USV v2.0. La aplicación se comunica por Bluetooth con la UAD. Esta basada en Android y permite visualizar los sensores, planificar la ruta, comprobar el estado del GPS, activar/desactivar el registro de datos, y establecer una variedad de configuraciones (Figura 3.10).

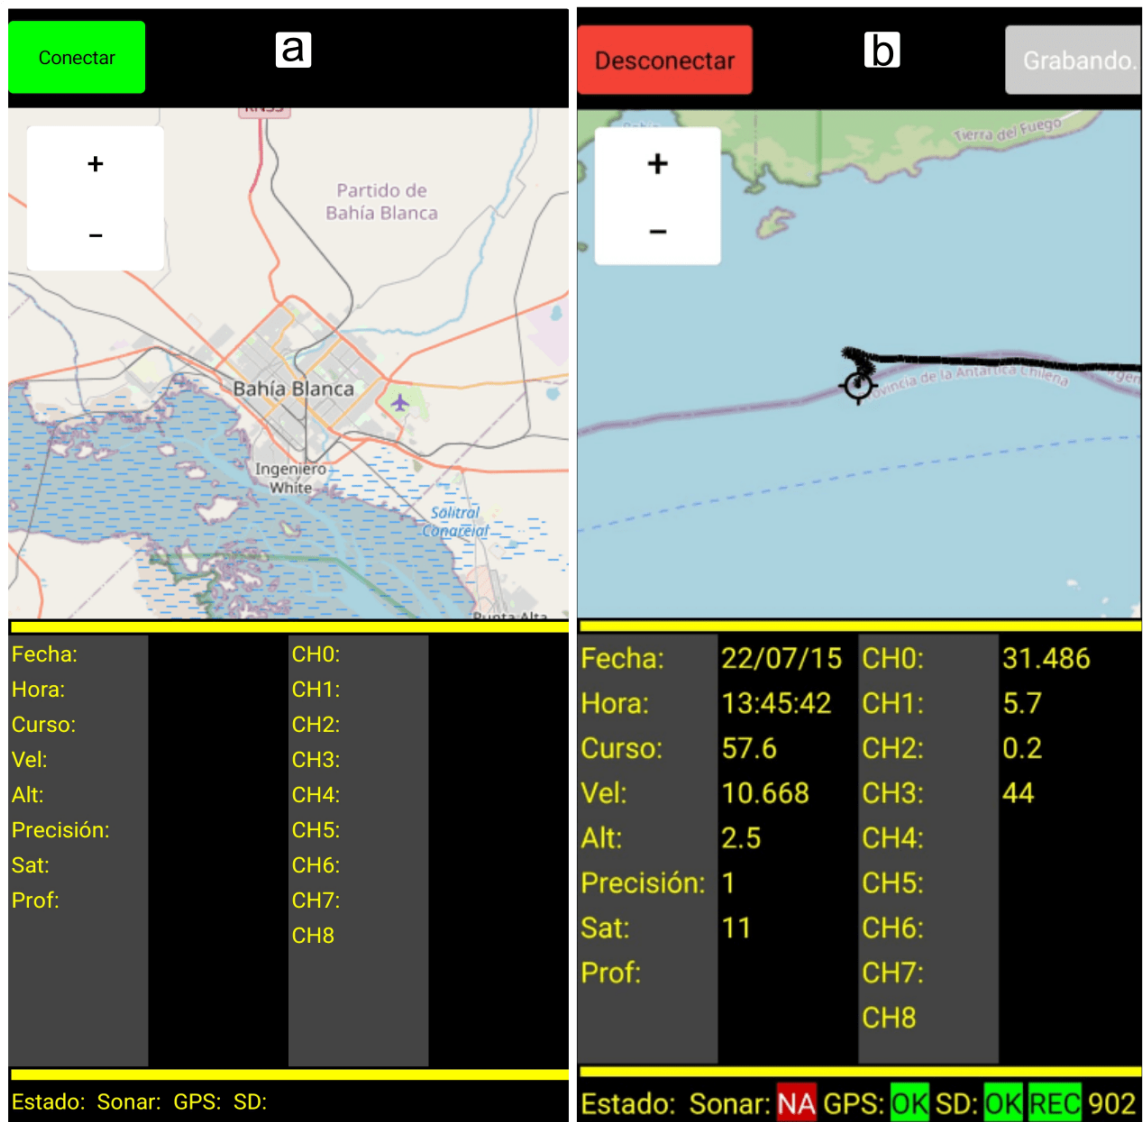


Figura 3.10: Aplicación móvil EMAC Monitor: (a) modo espera. (b) registrando datos.

### 3.3. Construcción del vehículo

Las descripciones de nuestras contribuciones se detallarán a continuación. Se deben seguir las especificaciones y capacidades de las partes comerciales de la plataforma propuesta para las instrucciones construidas.

#### 3.3.1. Casco

EMAC-USV v2.0 mantiene el mismo casco que su versión anterior. El casco fue construido en fibra de vidrio por constructores locales basándose en materiales y medidas estándar (por ejemplo, relación de aspecto) para las condiciones óptimas de navegación (Figuras 3.12a; 3.3, Tabla 3.1). Además, tras varias pruebas positivas, se creó un modelo renderizado en 3D del casco a partir de una herramienta CAD que sirve como gemelo digital. Con lo cual, el casco podría reproducirse utilizando fibra de vidrio o materiales plásticos como el acrilonitrilo butadieno estireno (ABS) utilizado por las impresoras 3D, y el cloruro de polivinilo (PVC) utilizado en rotomoldeo.

#### 3.3.2. Unidad de adquisición de datos y sensores

La unidad de adquisición de datos y algunos sensores de calidad del agua (es decir, temperatura y CSS) que se describieron previamente se desarrollaron bajo una filosofía de arquitectura abierta y bajo costo. (Figuras 3.11a,b). El primer paso fue diseñar las placas de circuito impreso (PCB) de los módulos electrónicos para la UAD y sensores utilizando el software KiCAD. Las placas finales fueron probadas después de que los componentes electrónicos se soldaran en las placas PCB impresas. Cada placa tiene un microcontrolador que es la unidad principal de procesamiento y ha sido programada adecuadamente. El firmware se carga a través del puerto serie después de que los componentes de la UAD se han ensamblado (Figuras 3.11c-g). Utilizando el entorno de desarrollo integrado Arduino IDE, se compilan y cargan archivos de firmware en el registrador de datos. (Figura 3.11j).



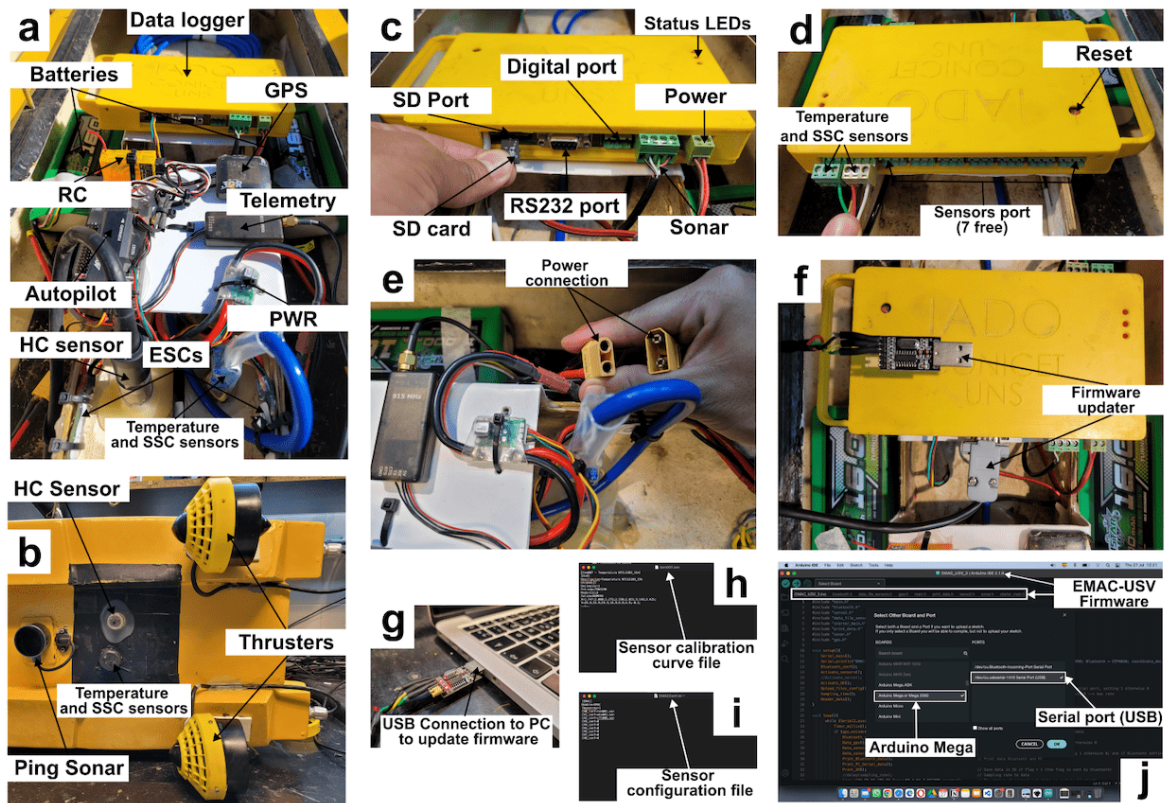


Figura 3.11: Vista de montaje de todos los componentes de EMAC-USV v2.0 y actualización del firmware: (a) Principales componentes internos. (b) Propulsores y sensores. (c) Puertos de configuración de la UAD. (d) Puerto de sensores de la UAD. (e) Conexión de alimentación. (f) Modo de actualización del firmware de la UAD. (g) Modo de actualización del firmware mediante conexión a PC. (h - i) Archivos de sensores. (j) Actualizador del firmware mediante Arduino IDE.

Para hacer que los sensores sean altamente impermeables, se usó resina epoxi para llenarlos por completo (Vitale et al., 2018). Además, los sensores se calibraron en el laboratorio para determinar la correlación entre sus valores reales y sus señales. La hoja de datos del fabricante contiene la curva de respuesta del sensor de temperatura, que contiene información eléctrica sobre la resistencia del termistor a diferentes temperaturas. Un termómetro de alta precisión (Valeport mini CT, precisión:  $\pm 0.01$  °C) sumergido en solución acuosa se utilizó para validar esta curva de respuesta a 5, 15 y 25 °C. El sensor óptico de retrodispersión se calibró de la siguiente manera: primero, se consideró que



el valor de agua pura conocido era cero para el sensor; luego, se utilizaron soluciones estándar de formazina a 20 y 200 NTU; y finalmente, se obtuvo una curva de respuesta de voltaje vs NTU de 0 a 200 NTU. Se utilizó al menos 1 L de solución para garantizar que el sensor se sumergiera por completo. Además, para evitar cualquier reflexión, se utilizó un recipiente negro.

### 3.3.3. Montaje

La distribución de las partes internas de la plataforma es flexible debido a la alta capacidad volumétrica del casco (6.2 L). Para colocar las piezas, es fundamental controlar los centros de masa y flotación, que deben estar en la misma posición relativa. El banco de baterías (uno a cada lado) y los demás componentes se ubicaron en el centro de la plataforma (Figuras 3.12b; 3.11a). Para evitar filtraciones de agua, la UAD y varios componentes de la UCC (GPS, control remoto, telemetría, PWR, y ESC) se colocaron en un soporte elevado desde el suelo del casco (Figura 3.11a). Se utilizaron dos propulsores que se posicionaron con precisión para lograr una condición de navegación ideal a un bajo costo de implementación (Figuras 3.3c, e; 3.11b).

## 3.4. Instrucciones de operación

**Paso 1: Planificación de la ruta de navegación.** En primer lugar, el usuario define la ruta en términos de un conjunto de waypoints utilizando el software Mission Planner. Luego, utilizando el software mencionado anteriormente, se carga la planificación de la ruta al módulo Ardupilot a través de telemetría. El sitio web [Mission Planner Software \(2023\)](#) incluye una descripción general de la implementación de Mission Planner (instalación, firmware de Ardupilot, conexiones, planificación de misiones, etc.).

**Paso 2: Preparación, transporte, y navegación.** Las baterías Li-Po deben estar completamente cargadas. Para evitar que las piezas se golpeen entre sí y se desconecten,

la plataforma debe transportarse en posición horizontal. El usuario inspecciona las partes interiores y las conexiones antes de cerrar la tapa y los pernos para evitar fugas de agua. Dado que puede haber obstáculos que impidan el paso del vehículo en el agua, se debe realizar una inspección general de la zona antes de comenzar la navegación. En caso de que esto suceda, se deben realizar correcciones en la planificación de la ruta. Es importante tener en cuenta los riesgos potenciales de los propulsores, especialmente cuando están en funcionamiento fuera del agua, como medida de seguridad del usuario.

**Paso 3: Monitorización y registro de datos en tiempo real.** Cada sensor se configura editando el archivo de texto asociado que contiene su curva de calibración y que se almacena en la tarjeta micro-SD en el directorio de sensores (Figuras 3.11c,h,i). Para activar o desactivar el registro de datos se usa la aplicación EMAC-Monitor (Figura 3.10), la cual a su vez permite ver en tiempo real la ubicación y lectura de todos los sensores dentro del rango de cobertura Bluetooth. Por último, los datos registrados se guardan en un archivo; cada archivo contiene los datos de localización GPS, la hora, la fecha y los propios datos detectados.

**Paso 4. Limpieza de la plataforma.** La limpieza de las partes externas de la plataforma, como el casco, los propulsores, y los sensores de calidad del agua, es necesaria después de su uso mediante el empleo de agua destilada.

### 3.5. Resultados

La Figura 3.12 muestra diferentes perspectivas de EMAC-USV v2.0. Para obtener una visión completa de las prestaciones del USV propuesto, se consideraron dos escenarios acuáticos complejos (dos pequeños estanques de estabilización de residuos y una parte de un canal de marea) para verificar y validar el funcionamiento de la plataforma.




Figura 3.12: Diferentes vistas de EMAC-USV v2.0: (a) USV antes de su puesta en funcionamiento. (b) Partes interiores del USV. (c) USV en funcionamiento.

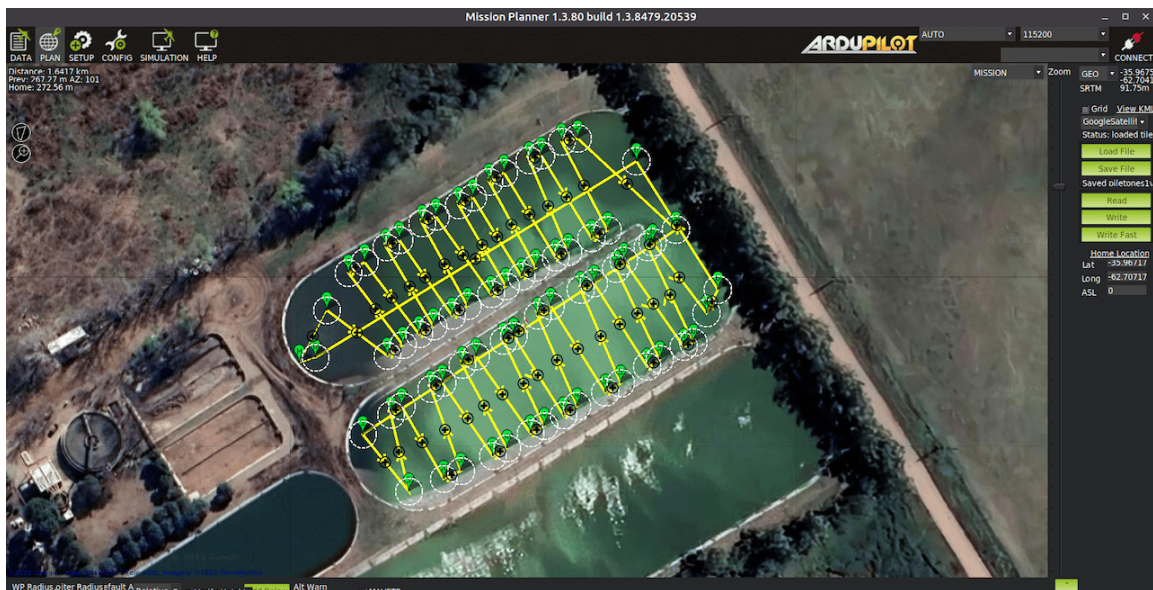
#### 3.5.1. Validación y caracterización

##### Escenario N<sup>o</sup> 1: Dos pequeños estanques de estabilización de residuos.

Se llevaron a cabo una serie de mediciones de parámetros de calidad y batimetría en dos pequeños estanques de estabilización de residuos ubicados en el oeste de la provincia de Buenos Aires (Argentina), en octubre de 2022. La descripción de las lagunas, la navegación del USV y las condiciones meteorológicas se presentan en la Tabla 3.3. En esta

**Tabla 3.3:** Descripción de los estanques monitoreados, navegación del USV, y condiciones meteorológicas.

Especificación	Estanque 1 (Izq)	Estanque 1 (Der)	Estanque 2
Área ( $m^2$ )	6322	6560	14722
Longitud del eje mayor (m)	153	156	274
Longitud del eje menor (m)	45	44	55
Profundidad promedio (m)	2.1	1.5	1.1
Recorrido total (m)	1236.8	1814.6	3667.9
Velocidad de navegación promedio ( $ms^{-1}$ )	0.76	0.98	0.85
Tiempo total de recorrido (min)	27.0	30.6	71.9
Condiciones climáticas	Velocidad media del viento = $10 ms^{-1}$ Dirección media del viento = $210^\circ$ Temperatura media = $25^\circ C$		

Figura 3.13: Ejemplo de la trayectoria diseñada en el escenario N<sup>o</sup> 1 (Estanque 1) utilizando el software Mission Planner.

campana, EMAC-USV v2.0 se operó de manera automática, para lo cual se diseñó la ruta de mapeo en el software Mission Planner tal y como puede observarse en la Figura 3.13, ocasionalmente se controló manualmente para evitar obstáculos en los estanques, como hierba o basura flotante. En este estudio, se empleó el conocido método de interpolación lineal para mapear los parámetros del agua y la batimetría. La trayectoria del vehículo, los mapas batimétricos, de temperatura, y CSS, así como los datos completos de respuesta de eco pertenecientes a un transecto de cada laguna, se muestran en la Figura 3.14. EMAC-USV v2.0 produjo patrones claros de distribución. Como era de esperar, las profundidades

aumentan hacia el centro alcanzando -3 y -1,7 m en las lagunas 1 -parte izquierda- y 2, respectivamente (Figuras 3.14a,e).

Los estanques mostraron un patrón similar de distribución de temperatura en respuesta a los efluentes líquidos que ingresan a los estanques, que alcanzan su máximo pico antes de la medición (Figuras 3.14b,f). En particular, se observó una marcada diferencia de 1.5 a 2 °C en la temperatura del agua en el estanque 1 (Figura 3.14b). Los detalles de la respuesta completa del eco están influenciados por las características del fondo de los estanques, que están cubiertos por una capa impermeabilizante basada en grava. Esta última produce cambios abruptos entre las dos interfaces (Figuras 3.14d,h).






Figura 3.14: Estanque 1 (partes izquierda y derecha) (a-d) y Estanque 2 (e-h): (a,e) Trayectoria del USV y mapas batimétricos. (b,f) Mapas de temperatura. (c,g) Mapas de concentración de sólidos en suspensión (CSS). (d,h) Datos completos de eco-respuesta pertenecientes a un transecto de cada estanque (ver línea roja en las Figuras. a y e).

## Escenario N<sup>o</sup> 2: Canal principal del estuario de Bahía Blanca.

En la parte interna del Canal Principal del Estuario de Bahía Blanca (Argentina), en mayo de 2023, se realizaron mediciones de batimetría y parámetros de calidad del agua como temperatura, CSS, y CCO. El canal de navegación tiene una profundidad de aproximadamente 13 metros. Debido a las condiciones del tráfico y las regulaciones legales en el lugar de las mediciones, la navegación del vehículo fue controlada manualmente vía RC. Los datos de alta calidad de la ecosonda multihaz de banda ancha (modelo Sonyc2020) proporcionados por el Consorcio de Gestión del Puerto de Bahía Blanca (CGPBB) se compararon con los datos batimétricos adquiridos por EMAC-USV v2.0 a través del Ping-sonar. El postprocesado incluyó correcciones por mareas que se realizaron durante la medición. El error cuadrático medio, el error absoluto medio, y el coeficiente de determinación (Ecuaciones: 4.1, 4.2 y 4.3) se utilizaron para analizar estadísticamente los datos (es decir, la profundidad). El error es prácticamente independiente del rango de profundidad (Figura 3.15), alcanzando valores entre 0.04 (MAE) y 0.05 m (RMSE). Los resultados muestran una correlación clara positiva ( $R^2 = 0.945$ ) entre los datos medidos y los de referencia.

La Figura 3.16 muestra que EMAC-USV v2.0 tuvo la capacidad de realizar mediciones de alta resolución. 4914 muestras cubrieron una distancia de 3317 metros. Los gráficos muestran que, a diferencia del CCO, la mayoría de los parámetros de calidad del agua parecen responder a las variaciones de profundidad.

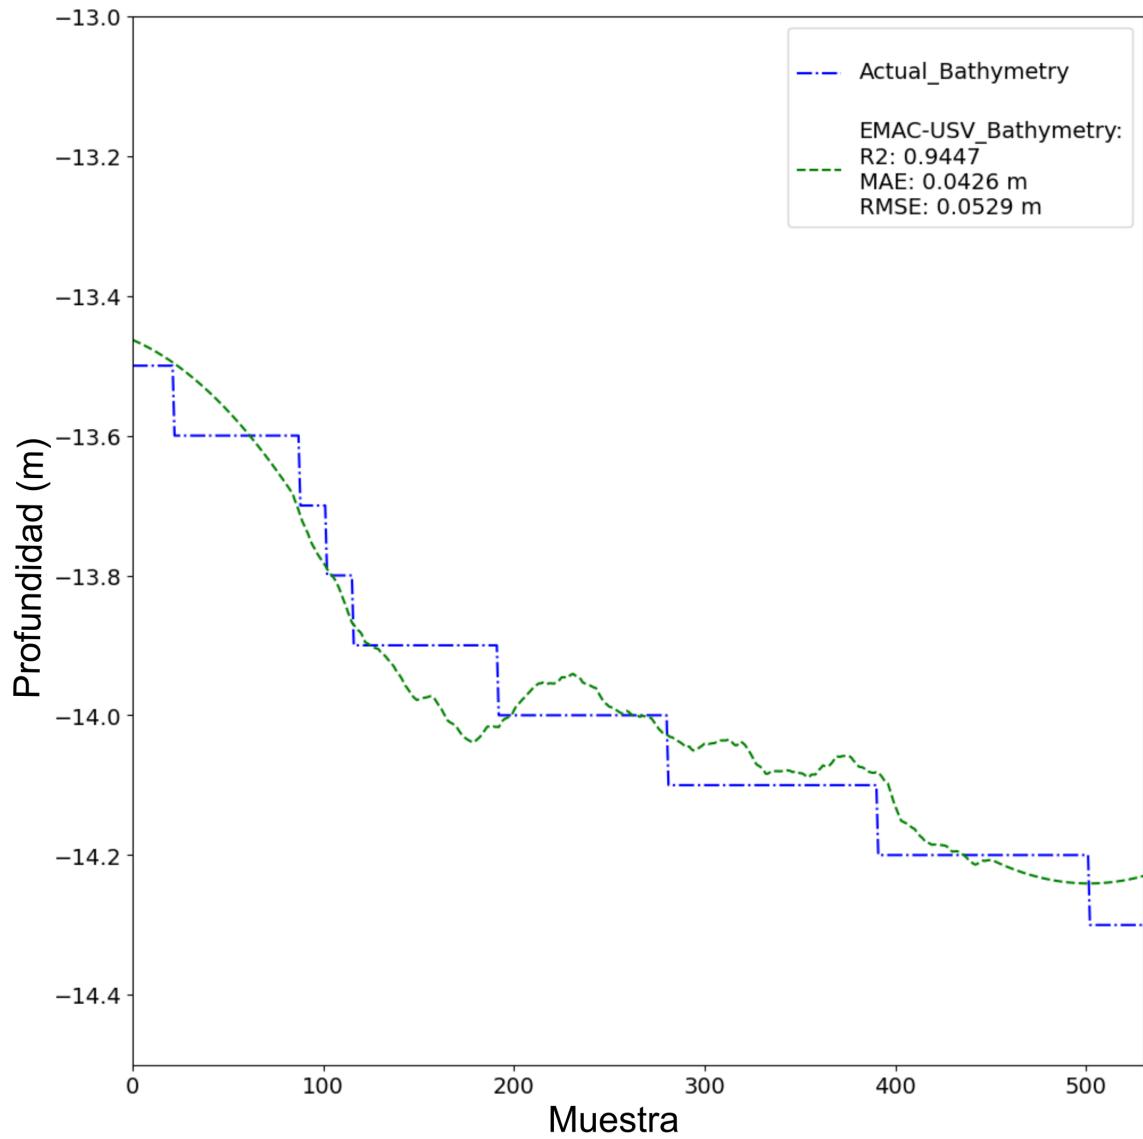


Figura 3.15: Evaluación de los datos batimétricos de EMAC-USV v2.0 mediante los datos de la ecosonda multihaz de banda ancha (modelo Sonyc2020).



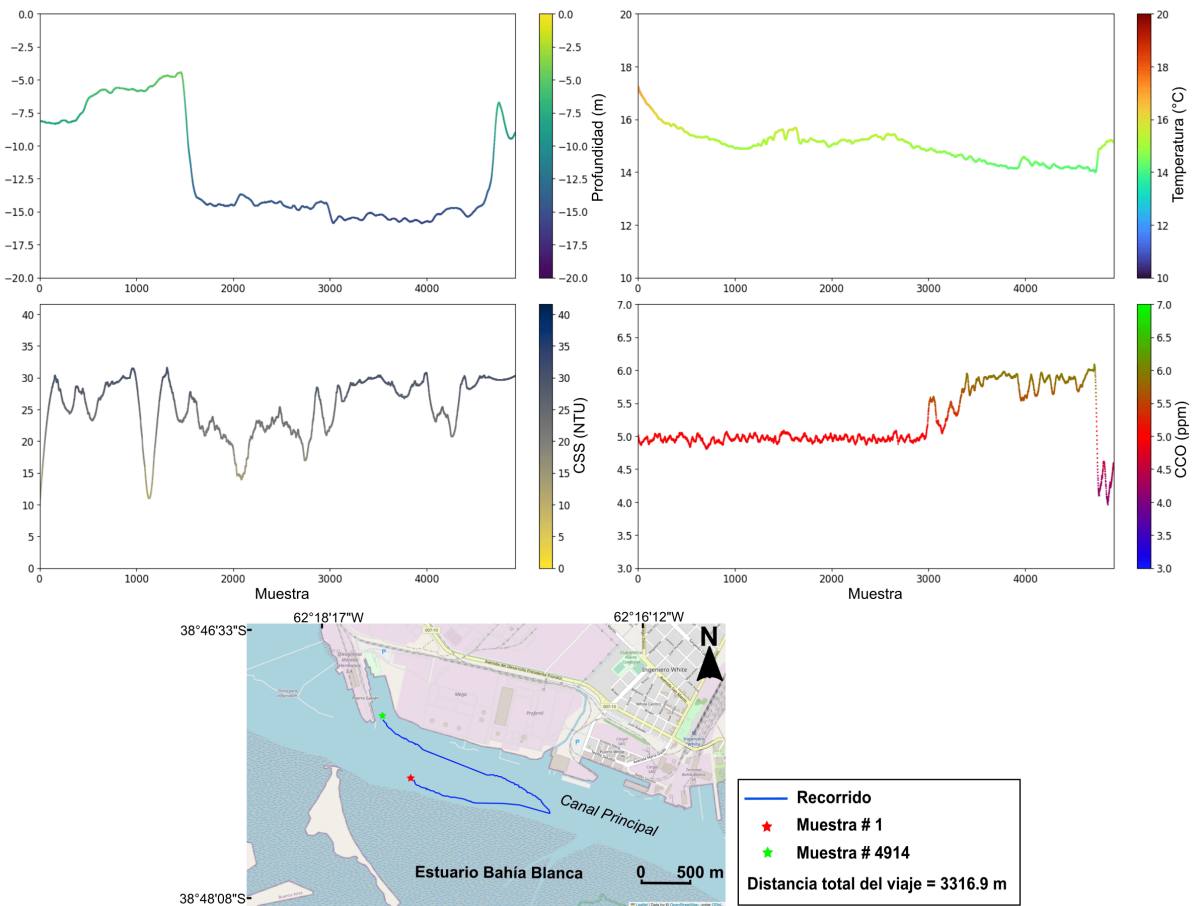


Figura 3.16: Mediciones de batimetría, temperatura, concentración de sólidos en suspensión (CSS) y concentración de carbono orgánico (CCO) en la parte interna del Canal Principal del Estuario de Bahía Blanca (Argentina).

# Capítulo 4

## Integración de tecnologías: Batimetría hiperspectral

En este capítulo, presentamos un enfoque innovador para la obtención de batimetrías densas y de alta resolución en áreas costeras caracterizadas por aguas turbias con alta sedimentación. Este método se basa en una metodología que fusiona imágenes hiperspectrales con datos batimétricos mediante modelos de aprendizaje de maquina.

La metodología se divide en dos estudios. El primero (sección 4.1) consiste en la determinación de una batimetría densa en un área costera de aproximadamente 800 m<sup>2</sup>, donde se utilizaron imágenes hiperspectrales adquiridas desde una plataforma aérea no tripulada junto con mediciones batimétricas puntuales. Las imágenes hiperspectrales se capturan mediante una cámara montada en un vehículo aéreo no tripulado, mientras que las mediciones batimétricas georreferenciadas se obtienen a través de un sonar instalado en un vehículo de superficie no tripulado (EMAC-USV). Este modelo permite obtener batimetrías densas con una resolución de aproximadamente 3.6 cm por píxel.

Basados en los resultados obtenidos en el primer estudio, se logró identificar el modelo de aprendizaje de maquina más adecuado, caracterizar los modelos en función de la profundidad, determinar la importancia de las bandas espectrales en el modelo, analizar el

efecto de entrenar los modelos con diferentes conjuntos de datos según la profundidad, y comparar el rendimiento del modelo batimétrico obtenido frente al método de interpolación kriging. Estos resultados se tomaron como referencia para extrapolar la metodología a otra zona de estudio con alta dinámica sedimentaria y aguas turbias. El objetivo es demostrar que la metodología es replicable a diferentes escalas y zonas de estudio con dinámicas complejas.

En este segundo estudio (sección 4.2), la metodología se extendió para generar batimetrías de alta resolución en una extensa área costera de aproximadamente 4000 km<sup>2</sup>. Para ello, se fusionaron imágenes satelitales hiperespectrales y datos batimétricos dispersos. Además, se implementó un método que permite aumentar la resolución de las imágenes satelitales a partir de la imagen pancromática disponible, generando un nuevo conjunto de imágenes hiperespectrales de alta resolución. Los datos hiperespectrales fueron tomados de la constelación PRISMA, mientras que los datos batimétricos se extrajeron de una carta náutica del área de estudio. Se obtuvieron dos modelos a partir de los dos conjuntos de imágenes hiperespectrales descritos, los cuales fueron optimizados para utilizar únicamente las bandas espectrales más incidentes en cada caso. Los modelos resultantes permiten obtener batimetrías con una resolución de 30 m y 5 m por píxel, respectivamente, lo que facilita la generación de mapas de alta resolución del área de estudio.

## **4.1. Batimetría densa en zonas costeras turbias a partir de imágenes hiperespectrales aéreas**

A continuación, se expone en detalle la metodología (ver Figura 4.1) que permite obtener batimetrías densas a partir de la fusión de imágenes hiperespectrales basadas en UAV con datos de sonar de un USV mediante algoritmos de aprendizaje de máquina.

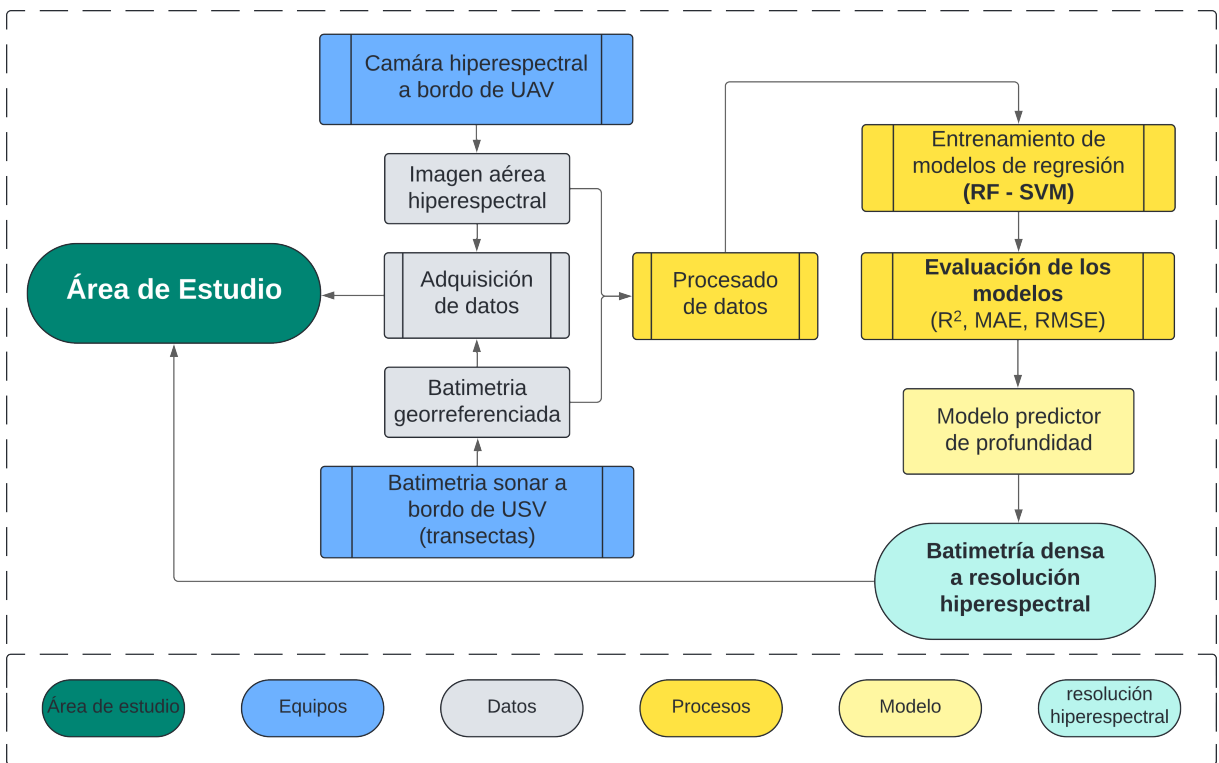


Figura 4.1: Batimetría a partir de la fusión de imágenes hiperspectrales aéreas y mediciones de ecosonda mediante modelos de aprendizaje de máquina: Diagrama de flujo de las etapas y metodología propuesta

La metodología aplicada permitió obtener una batimetría densa en una zona submarina de aproximadamente  $800 \text{ m}^2$  (ver también [Martinez Vargas et al. \(2021a,b\)](#)). Al igual que en los trabajos previos mencionados, no se pretende proporcionar estimaciones de los parámetros físicos de transporte de luz. En cambio, el propósito de esta metodología es comprender la viabilidad y practicidad de obtener una batimetría densa útil mediante la fusión de imágenes hiperspectrales aéreas y mediciones de ecosondas. Los datos de sonar a lo largo de algunas transecciones se tomaron como verdad de referencia para entrenar modelos de regresión de bosques aleatorios y máquinas de soporte vectorial, capaces de predecir la profundidad real en función de los números digitales en las bandas espectrales. El mejor modelo se aplicó al conjunto de imágenes hiperspectrales, obteniendo una batimetría densa para toda la zona de estudio.

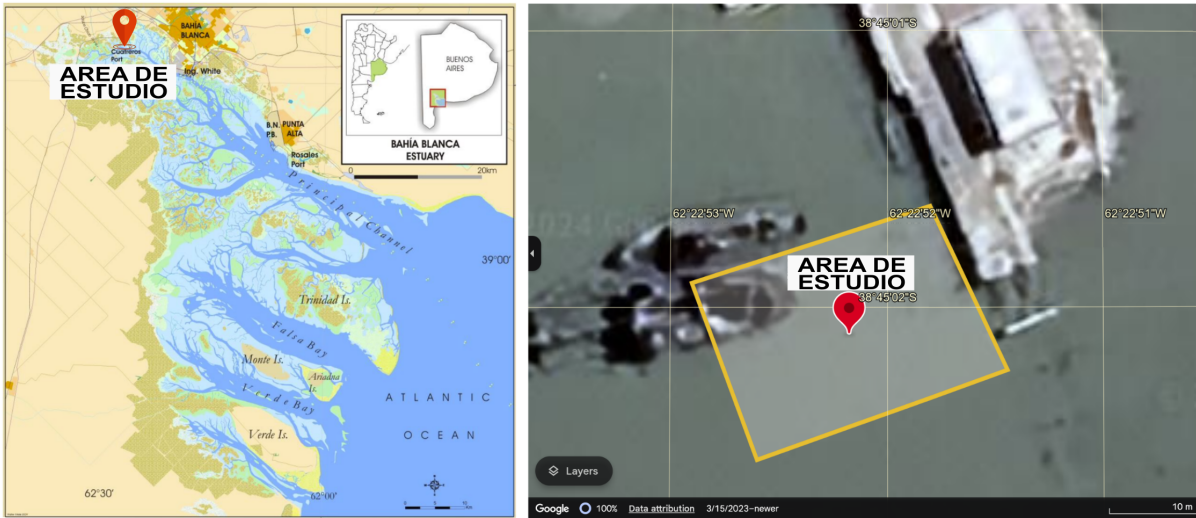


Figura 4.2: Área de Estudio: (a) (Izq) Estuario de Bahía Blanca (Fuente: Instituto Argentino de Oceanografía); (b) (Der) Mapa de localización, Puerto de Cuarteros (Fuente: Google Earth).

#### 4.1.1. Área de estudio

El área de estudio se ubica al noreste del estuario de Bahía Blanca, cerca del asentamiento urbano de General Cerri y del puerto de Cuarteros (Figura 4.2). En esta ubicación, la profundidad del sitio, los ciclos de marea, y las características geomorfológicas son representativos de otras porciones poco profundas, que cubren la mayor parte del área inundada del estuario. Además, las instalaciones portuarias proporcionan un acceso adecuado y permiten el funcionamiento del UAV y USV, además el muelle sirve como objetivo rígido para la geolocalización. Por último, la zona de estudio se encuentra dentro de la cobertura de una estación diferencial del sistema de posicionamiento global (DGPS). Esto facilita el procedimiento completo de adquisición de datos.

#### 4.1.2. Batimetría USV

Para realizar las mediciones batimétricas es indispensable observar el cambio de mareas en el área de estudio. Si bien el cambio de marea depende de la dinámica del lugar,

en el estuario de Bahía Blanca suele ser rápido y variado, influenciado por factores como la amplitud de marea, la geografía del estuario, condiciones meteorológicas y corrientes de marea. Por ello, es vital consultar las tablas de marea locales y los pronósticos meteorológicos para obtener información precisa sobre los cambios de marea en Bahía Blanca, ya que pueden variar significativamente de un día para otro. Basado en los datos disponibles del Consorcio de Gestión del Puerto de Bahía Blanca (CGPBB), se validaron las condiciones de marea adecuadas para el área de estudio. La adquisición de datos se llevó a cabo durante la marea alta y con condiciones de viento adecuadas para evitar el balanceo del USV, el 22 de febrero de 2018.

Un vehículo de superficie no tripulado denominado EMAC-USV (Figura 3.1) en su primera versión se utilizó para llevar a cabo las adquisiciones batimétricas basadas en sonar a lo largo de cinco transectos (Figura 4.3). Las características del vehículo se presentan en la sección 3.1. EMAC-USV incluye un sonar Garmin Echo 100 de 200  $kHz$ , que permitió adquirir las mediciones batimétricas georreferenciadas. Para gestionar la navegación y el monitoreo del vehículo se utilizó el software Mission Planner, que permite definir la ruta del EMAC-USV v1.0 mediante la marcación de waypoints dentro de un área de interés. La adquisición se realizó a una tasa de 5  $Hz$  mientras el vehículo se desplazaba a una velocidad promedio de 1  $m/s$ , con el fin de obtener un muestreo aproximadamente equidistante. Se tomaron un total de 100 muestras batimétricas (20 por transecto, de aproximadamente 30 metros de longitud cada uno), cubriendo un área de alrededor de 300  $m^2$ . En la Figura 4.3 se muestran los transectos (etiquetados como TA, TB, TC, TD y TE) y las ubicaciones de adquisición.

### 4.1.3. Datos hiperspectrales UAV

Dado que el cambio de marea en el área de estudio puede variar significativamente en el lapso de una hora, y teniendo como referencia los datos de marea alta proporcionados por el CGPBB, se realizó la adquisición de las imágenes hiperspectrales minutos después



Figura 4.3: Transectos de batimetría en el área de estudio sobre una imagen a pseudocolor adquiridos mediante un sonar abordo del vehículo EMAC-USV. Los puntos en color y de forma circular representan las mediciones con profundidad mayor (azul), media (amarillo) y menor (magenta).

de la batimetría realizada por EMAC-USV v1.0. Esto se hizo con el objetivo de registrar los datos espectrales y batimétricos en las mismas condiciones de marea. Sin embargo, es factible realizar la adquisición de los datos espectrales días posteriores al registro de los datos batimétricos, ya que la forma del fondo no cambiará a menos que ocurra un cambio significativo en las condiciones meteorológicas del área de estudio.

Las imágenes hiperespectrales se adquirieron utilizando un espectrómetro hiperespectral Rikola (Rikola Ltd., Oulu, Finlandia) (Figura 4.4a), que se basa en un interferómetro Fabry-Pérot (Rikola, 2015). Este dispositivo se montó a bordo de un vehículo aéreo no tripulado (UAV) Quantum Spider 700 Professional Multirotor (Figura 4.4b). La adquisición de imágenes se llevó a cabo con el UAV manteniéndose de manera constante sobre





Figura 4.4: Adquisición de imágenes hiperespectrales: (a) Cámara hiperespectral Rikola. (b) Vehículo aéreo no tripulado (UAV).

la región de interés a una altura promedio de 30 m sobre el nivel del suelo, resultando en una huella de imagen de  $36 \times 22$  m. El tiempo de exposición se ajustó entre 10 y 20 milisegundos, teniendo en cuenta la radiación ascendente y descendente para evitar el efecto de desenfoque por movimiento. Cada banda espectral se adquirió en un formato de 12 bits y resolución de  $1024 \times 648$  píxeles, lo que equivale a un tamaño de píxel de aproximadamente 3.6 cm. La huella de la imagen es inversamente proporcional a la resolución espacial. A mayor altura se logra registrar una mayor área de la escena, pero con menor resolución espacial, resultando en un tamaño de píxel mayor. Para este estudio, era importante tener una resolución espacial densa en el orden de los centímetros. Sin embargo, la cámara hiperespectral Rikola también puede capturar escenas a alturas en el orden de cientos de metros, donde puede ser acoplada a pequeñas aeronaves tripuladas o no tripuladas, permitiendo mapear grandes extensiones en una sola captura. Esto es útil para aplicaciones como la teledetección de enfermedades en cultivos y el análisis de minerales, entre otras muchas aplicaciones. Siendo la altura de captura un factor que depende del tipo de aplicación que se desee realizar.

Únicamente fue posible adquirir en secuencia 24 bandas espectrales en el rango de 500 a 900 nm en línea (es decir, a bordo). La selección de estas bandas se realizó siguiendo



varios criterios, que incluyen las distribuciones espectrales de la transmitancia del agua, la absorción de sedimentos en suspensión, la retrodispersión del fondo, y el objetivo de verificar la presencia de zooplancton y trazas de productos químicos. En la Tabla. 4.1 se presentan las longitudes de onda reales (en la primera fila) y los números digitales del primer punto de cada transecto, junto con sus respectivas profundidades medidas.

#### 4.1.4. Procesado de datos

Cada uno de los 24 fotogramas correspondientes a las bandas espectrales fue procesado con el software Rikola Imager para corregir la distorsión de la lente y calibrar el nivel de negro. Los números digitales en el rango de 0 a 4095 fueron convertidos a radiancia espectral, expresada en  $mW/(m^2 * sr * nm)$ . En la Figura 4.5 puede observarse la radiancia espectral de algunas bandas espectrales (500, 628, 710, y 892 nm), donde es notable como la reflectancia de cada una de las bandas cambia con respecto a la banda espectral y a la zona de la escena que se este observando.

A pesar de que la adquisición de las imágenes se realizó en condiciones de viento favorables, los pequeños balanceos no compensados del UAV que ocurrieron entre las adquisiciones de las bandas individuales resultaron en desplazamientos notables entre pares de fotogramas, en la mayoría de los casos, inferiores a 10 píxeles. Para registrar adecuadamente la ubicación de los píxeles, se empleó el algoritmo SIFT (Lowe, 2004) para identificar un conjunto de 100 puntos clave con los cuales todos los fotogramas fueron registrados en la misma referencia mediante una homografía de cuatro puntos (Szeliski, 2010). Los fotogramas fueron finalmente geolocalizados utilizando las coordenadas diferenciales del sistema de posicionamiento global (DGPS) de puntos rígidos conocidos. Con las coordenadas de las adquisiciones de EMAC-USV v1.0, las 100 muestras batimétricas fueron registradas y ubicadas dentro de los fotogramas.

De esta manera, se construyó un conjunto de datos de  $100 \times 25$  (Tabla 4.1). Cada fila corresponde a una muestra batimétrica y a los valores de las 24 bandas espectrales

**Tabla 4.1:** Longitudes de onda hiperespectrales, números digitales, y profundidades del primer punto en los cinco transectos.

Transectos	Banda Espectral (nm)								
	500	510	525	555	560	600	620	628	670
TA	1934.0	4643.5	9053.8	10007.5	10767.5	12309.5	13311.0	13749.8	11556.2
TB	1783.4	4630.1	9026.0	9940.4	10740.3	12323.9	13344.1	13774.4	11587.1
TC	1825.7	4536.7	8844.9	9873.4	10521.1	12194.2	13245.5	13665.2	11556.2
TD	1835.1	4656.8	9151.3	10208.5	10781.4	12424.8	13771.3	14083.8	12159.5
TE	1821.0	4456.6	8733.5	9662.8	10356.7	12093.3	13311.2	13847.2	12020.3

Banda Espectral (nm)									
675	678	685	698	700	705	710	725	740	750
11994.5	11925.5	11617.7	10309.1	10203.3	10553.8	10591.9	8791.8	6703.4	6055.9
12073.7	12021.6	11779.3	10309.1	10449.3	11027.8	10849.5	9402.8	7461.9	7923.6
12026.2	12037.6	11520.8	10199.6	10199.1	10411.6	10608.0	8842.7	6509.4	6225.7
12659.2	12709.9	12118.7	10778.4	10934.3	11343.8	11541.7	9996.8	8308.7	7885.9
12564.2	12453.8	12037.8	10872.3	10824.8	11233.2	11348.5	10217.5	8502.7	8489.6

Banda Espectral (nm)					Batimetría (m)
820	840	870	876	892	Profundidad
6000.6	5186.4	4336.0	4226.2	4054.9	8.274
6289.1	5506.6	4725.1	4397.6	4197.7	8.452
5962.1	5186.4	4391.6	4112.0	3997.8	8.172
7885.4	6787.2	5892.5	5511.2	5311.3	7.986
8308.5	7043.3	6170.5	5711.1	5568.3	7.828

adquiridas en el mismo punto, después de un suavizado gaussiano de  $3 \times 3$ . Basado en los puntos de profundidad menor, media y mayor marcados en la Figura 4.3, se generó la firma espectral para estos puntos basados en las 24 bandas de la imagen hiperespectral. El resultado de la firma espectral para estos puntos se puede observar en la Figura 4.5e, donde se observa una notable diferencia para el espectro de reflectancia de menor profundidad con respecto a los de profundidad media y mayor. Sin embargo, las diferencias entre el espectro de reflectancia para los puntos de profundidad media y alta son ligeramente diferentes, lo que indica que es más difícil discernir la profundidad a medida que esta aumenta. Dentro de los aspectos que más afectan la reflectancia de la luz en el agua se destacan la presencia de sedimentos en suspensión, la presencia de materia orgánica, la profundidad del fondo, entre muchos otros factores que se exponen en el capítulo 2.3.1.

Este conjunto de datos espectrales serán usados por los modelos de aprendizaje de máquina para discernir la profundidad en función de las mediciones batimétricas del área de estudio.

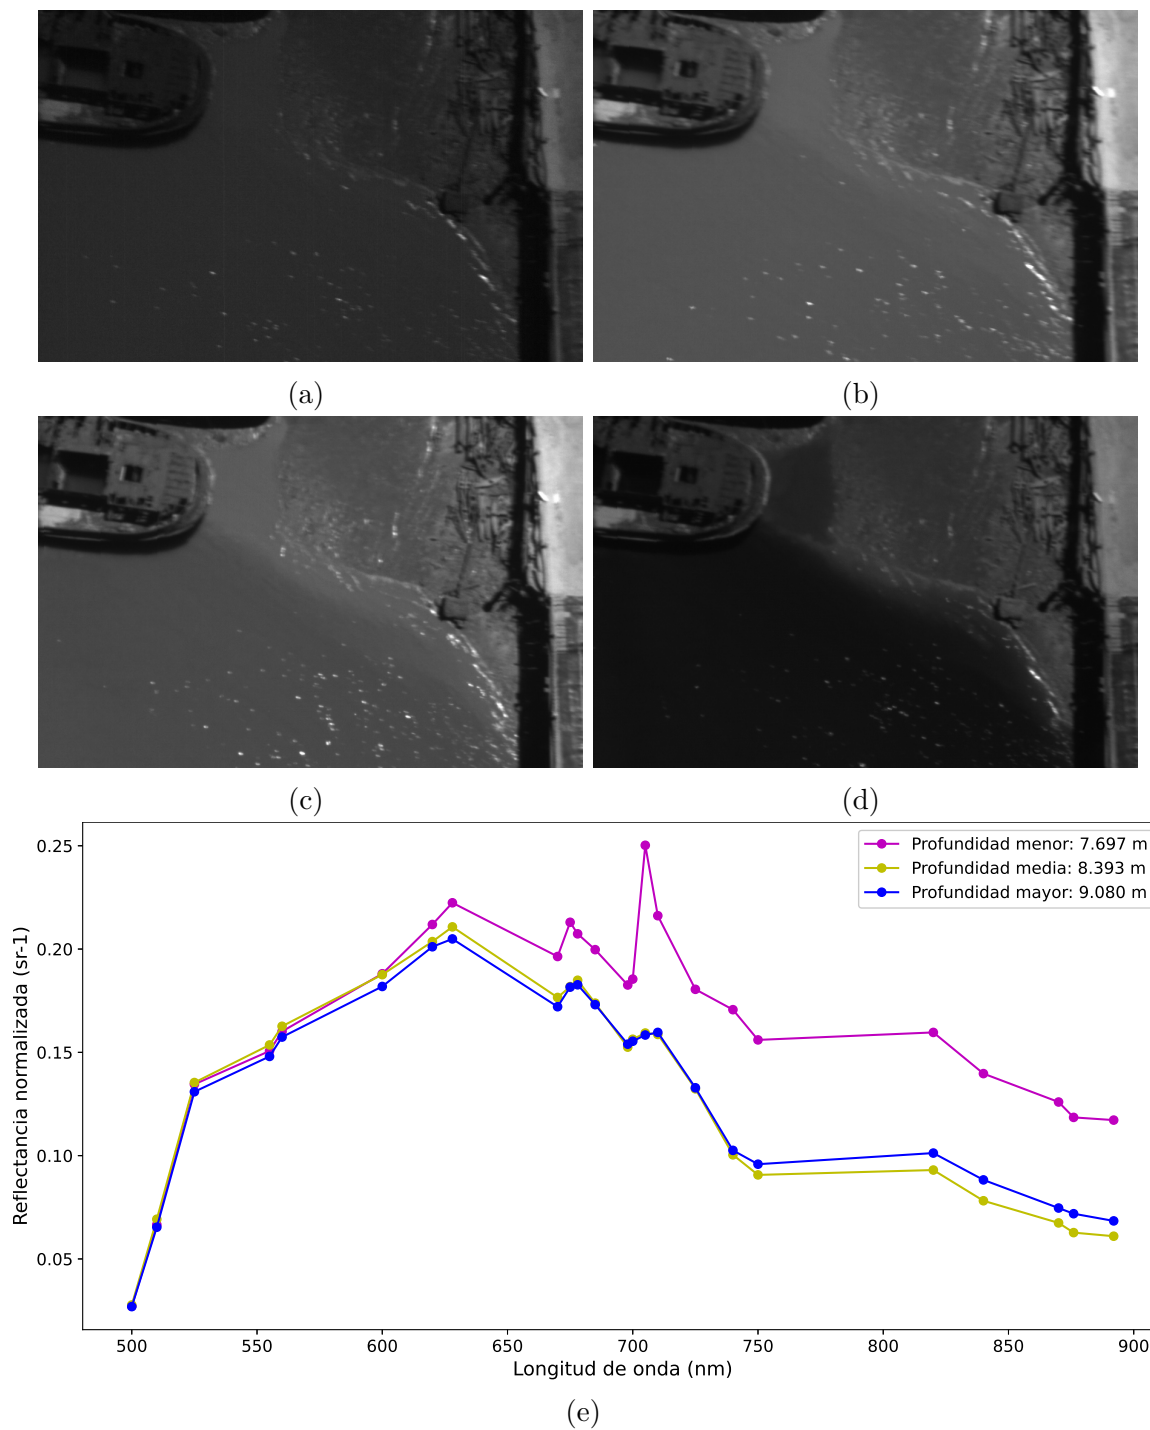


Figura 4.5: Diferencias espectrales para la zona de estudio: Vista de diferentes bandas hiperespectrales (a) 500 nm. (b) 628 nm. (c) 710 nm. (d) 892 nm. (e) Reflectancia para los puntos batimétricos de profundidad menor, media y mayor marcados en la Figura 4.3.

### 4.1.5. Entrenamiento de los modelos

Los modelos de regresión RF y SVM fueron entrenados con el conjunto de datos previamente descrito, utilizando los 24 valores de las bandas espectrales como variables explicativas y la medida batimétrica real como variable explicada. Se utilizó la implementación estándar de la biblioteca Scikit-Learn de Python (Pedregosa et al., 2011). La afinación de hiperparámetros se llevó a cabo mediante RandomizedSearchCV, usando validación cruzada k-fold con  $k = 3$ . El entrenamiento se realizó con la partición estándar del 60 %, 20 %, 20 % para entrenamiento, validación, y testeo, respectivamente, con el fin de evitar el sobreajuste.

### Métricas de evaluación

Para evaluar el rendimiento de los modelos se utilizaron las medidas de precisión típicas (Ecuaciones. 4.1, 4.2, 4.3) que consideran diferentes aspectos de la precisión de las predicciones: error cuadrático medio (RMSE), error absoluto medio (MAE), y coeficiente de determinación ( $R^2$ ), donde  $x_i$  es el valor estimado mediante el modelo de regresión en el punto  $i$  y  $y_i$  es el valor real en el mismo punto.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (4.1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (4.2)$$

$$R^2 = \left( \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \right)^2 \quad (4.3)$$

#### 4.1.6. Resultados del entrenamiento y evaluación de los modelos

El mejor modelo y la iteración con el conjunto de prueba (datos no vistos por el modelo) fue para el modelo de bosques aleatorios (RF), con un error cuadrático medio de 0.166 m y un coeficiente de determinación  $R^2 = 0.815$ . El error absoluto promedio de RF fue de 0.123 m, lo que representa menos del 13% del rango de profundidad real. Los resultados para ambos modelos se pueden observar en la Tabla 4.2. Para comparar las predicciones de los modelos, se realizó una predicción del primer punto de cada transecto (puntos más distantes de la costa) y se comparó con la batimetría de referencia, validando el error absoluto para cada uno de estos. Los resultados se presentan en la Tabla 4.3.

**Tabla 4.2:** Precisión de los modelos para el conjunto validación ( $R^2$ , RMSE, MAE)

Métrica	Modelos de Regresión	
	RF	SVM
$R^2$	0.815	0.720
RMSE (m)	0.166	0.203
MAE (m)	0.123	0.174

El modelo RF presenta un rendimiento superior en términos de  $R^2$ , error cuadrático medio (RMSE), y error absoluto promedio (MAE) en comparación con el modelo SVM. En la Figura 4.7(a), se presenta un gráfico de dispersión de la predicción de RF versus la batimetría real para los 100 puntos de datos. El ajuste lineal del modelo tiene una pendiente de 1.069 para datos no vistos previamente, lo que indica que el modelo RF subestima levemente las profundidades mayores y sobrestima levemente las menores. Por otro lado, el modelo SVM (Figura 4.7(c)) presenta un mejor ajuste lineal con una pendiente de 0.998 para los datos de validación. Sin embargo, para el conjunto de datos de entrenamiento, la pendiente de ajuste de los datos es 1.169. Los resultados de SVM muestran que el modelo subestima las profundidades mayores a 8.5 m. Aunque SVM tiene un mejor ajuste para los datos de validación, el modelo RF tiene un ajuste general superior para todo el conjunto de datos y mejores tasas de error en términos de MAE y RMSE para el conjunto de datos de validación. Esto sugiere que el modelo RF es más robusto y confiable para predicciones en todo el rango de profundidades evaluadas.

**Tabla 4.3:** Predicción de los modelos de regresión para los primeros cinco puntos de los transectos

Transectos	Batimetría (m)	Predicción de los Modelos (m)			
		RF	Error Abs.	SVM	Error Abs.
TA	8.274	8.279	0.005	8.402	0.128
TB	8.452	8.227	0.225	8.303	0.149
TC	8.172	8.330	0.158	8.426	0.254
TD	7.986	8.014	0.028	8.123	0.109
TE	7.828	8.029	0.201	8.170	0.141

Solo se identifican cuatro valores atípicos en el modelo RF con un error absoluto superior a 0.2 m (Figura 4.7(b)), mientras que para el modelo SVM (Figura 4.7(d)) se encontraron seis puntos con un error absoluto mayor a 0.4 m. Se identificaron los puntos atípicos del mejor modelo basado en bosques aleatorios mediante la marcación en color negro sobre la pseudoimagen (ver Figura 4.6) de aquellos puntos donde la predicción del modelo RF genero un error mayor a 0.2 m.




Figura 4.6: Identificación de puntos con error absoluto mayor a 0.2 m en la predicción del modelo batimétrico RF marcados sobre la pseudoimagen en color negro.

Esta marcación mostró que estos puntos se encuentran más cerca de la costa, lo que puede indicar que el mayor error en dichos puntos se debe a efectos del oleaje sobre la imagen hiperspectral, más notorio en los bordes de la costa. Dichas variaciones en el oleaje son captadas por la cámara hiperspectral Rikola, dado que a la cámara le toma alrededor de 15 segundos realizar una captura completa (24 bandas). Esto provoca que pequeñas variaciones en la escena sean captadas individualmente por las bandas. Otro

factor que puede considerarse es que, en el borde de la costa, podría haber acumulación de plancton, basura u objetos no visibles que alteren tanto la medición de la ecosonda como la captura hiperespectral.

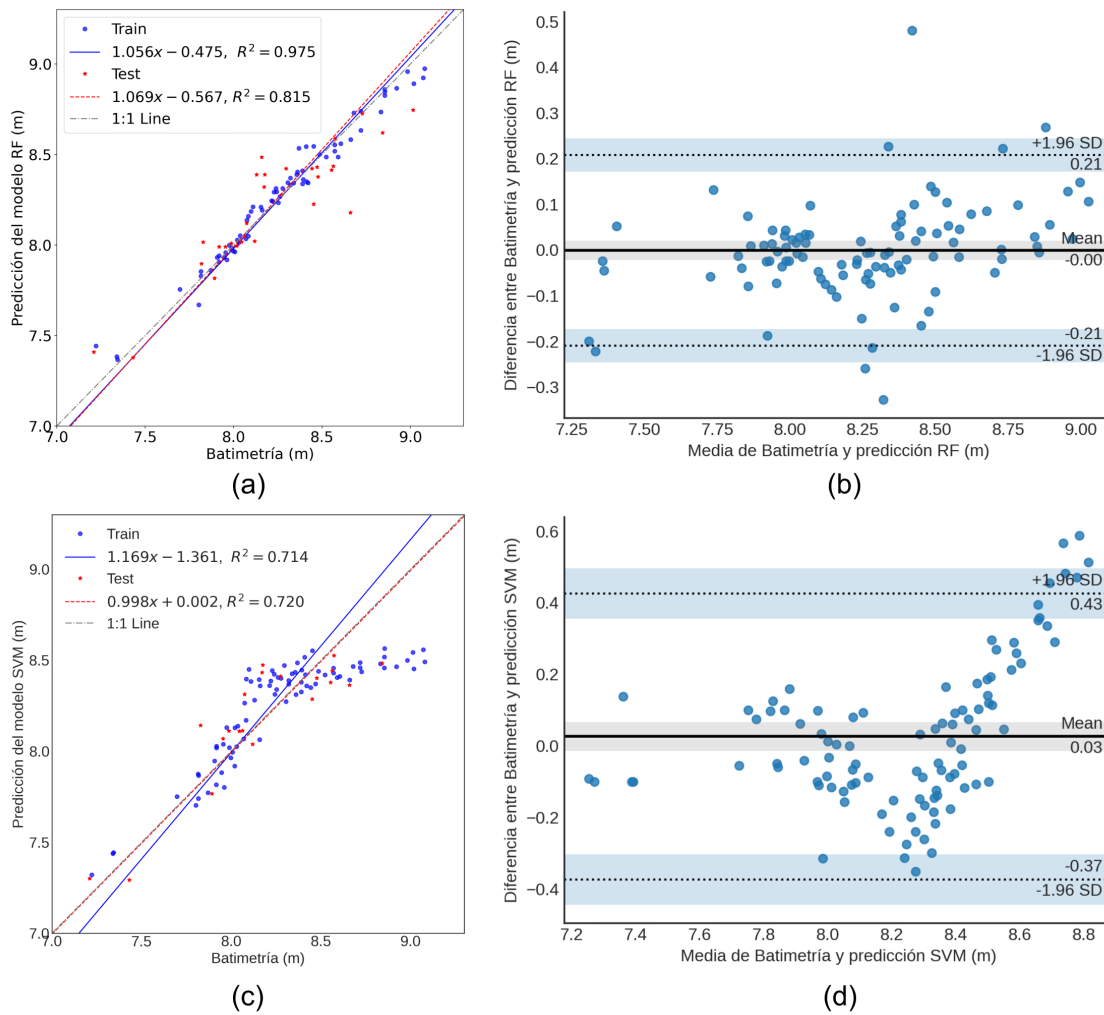


Figura 4.7: Resultados de los modelos batimétricos basados en imágenes hiperespectrales aéreas y mediciones de ecosonda para bosques aleatorios (RF) y maquinas de soporte vectorial (SVM) (profundidad estimada frente a profundidad de referencia en el entrenamiento y la validación de los modelos, y diagrama de Bland-Altman): (a, b) RF. (c, d) SVM.



### 4.1.7. Estudio de ablación batimétrica

Se llevaron a cabo dos pruebas de ablación a partir de los transectos, con el objetivo de ver la robustez de los modelos frente a un menor número de datos para el conjunto de entrenamiento. En la primera, se generaron dos modelos diferentes con datos de los transectos TA y TB, y de los transectos TD y TE, respectivamente (Figura 4.8(a)).




Figura 4.8: Pruebas de ablación: (a) Por transectos TAB Y TDE. (b) Por zonas de: (Izq) Mayor profundidad; (Cen) Profundidad intermedia; (Der) Profundidad superficial.



**Tabla 4.4:** Exactitud de los modelos según el Área, Transectas, y Zonas ( $R^2$ , RMSE, MAE). (C) predicción Transecta C. (S) Profundidad superficial. (I) Profundidad intermedia. (D) Mayor profundidad. (*en negrita se marcan los peores resultados tomando como referencia  $R^2$* ).

	Modelos por Transectas (AB) y (DE)							
	RF-AB	RF-AB(C)	SVM-AB	SVM-AB(C)	RF-DE	RF-DE(C)	SVM-DE	SVM-DE(C)
$R^2$	0.822	0.855	<b>0.577</b>	0.685	0.828	0.793	<b>0.607</b>	0.721
RMSE (m)	0.138	0.147	<b>0.213</b>	0.217	0.102	0.176	<b>0.155</b>	0.204
MAE (m)	0.118	0.120	<b>0.189</b>	0.177	0.073	0.135	<b>0.123</b>	0.153

Modelos por Zona Superficial (S) y Profunda (D)							
RF-S	RF-S(D)	SVM-S	SVM-S(D)	RF-D	RF-D(S)	SVM-D	SVM-D(S)
0.861	<b>-4.372</b>	0.793	<b>-5.801</b>	0.830	<b>-8.607</b>	0.879	<b>-14.199</b>
0.093	<b>0.565</b>	0.113	<b>0.635</b>	0.072	<b>0.841</b>	0.060	<b>1.057</b>
0.068	<b>0.509</b>	0.098	<b>0.585</b>	0.055	<b>0.785</b>	0.045	<b>0.951</b>

Modelos Zona Intermedia (I)					
RF-I	RF-I(S)	RF-I(D)	SVM-I	SVM-I(S)	SVM-I(D)
0.861	<b>-0.201</b>	<b>-1.029</b>	0.618	<b>-0.718</b>	<b>-1.362</b>
0.093	<b>0.297</b>	<b>0.347</b>	0.124	<b>0.326</b>	<b>0.374</b>
0.068	<b>0.184</b>	<b>0.284</b>	0.097	<b>0.216</b>	<b>0.312</b>

Luego, los modelos resultantes se utilizaron para la predicción de la profundidad a lo largo del transecto TC. En la segunda prueba, el área de estudio se dividió en tres zonas según la profundidad (Figura 4.8(b)), tomando un tercio de cada transecto (izquierda para la zona profunda, centro para la zona intermedia, y derecha para la zona más somera). Luego, se generó un modelo y se evaluó de forma independiente para cada zona. Los resultados de estos experimentos se muestran en la Tabla 4.4. En las Figuras 4.9a y 4.9b pueden verse dos diagramas de dispersión, de la predicción de los diferentes modelos frente a la batimetría real incluyendo las pruebas de ablación descritas anteriormente. En estas figuras, se observa que los modelos basados en RF tienen una pendiente más cercana a la identidad, lo que indica una mayor correlación con respecto a la variable explicada. Al comparar los resultados obtenidos para cada prueba entre los modelos basados en RF y las SVM, se evidencia que el rendimiento de los modelos RF es superior en casi todos los casos, excepto en la prueba por zona de mayor profundidad, donde las SVM mostraron un mejor rendimiento. Las pruebas basadas en transectas que toman menos de la mitad de los puntos, para su entrenamiento demuestran que el modelo RF es más robusto y




Figura 4.9: Profundidad predicha por los modelos batimétricos por Transectos y Zonas vs profundidad real para el conjunto de datos de testeo (TAB) Transectas A y B. (TDE) Transectas D y E. (S) Profundidad superficial. (I) Profundidad intermedia. (D) Mayor profundidad: (a) Bosques aleatorios (RF). (b) Maquinas de soporte vectorial (SVM).

puede realizar predicciones de puntos no vistos por el modelo, manteniendo casi la misma exactitud en los resultados frente al modelo inicial que emplea todo el conjunto de datos.

Asimismo, como se esperaba, las pruebas por zona muestran que los modelos son consistentes cuando se entrenan con puntos de profundidad similar y predicen profundidades dentro de este rango (ver Tabla 4.4: *RF-S*, *SVM-S*, *RF-D*, *SVM-D*, *RF-I*, *SVM-I*), obteniendo predicciones con una exactitud incluso superior al modelo inicial de referencia. Sin embargo, los resultados también muestran que estos modelos no son adecuados cuando se desea extrapolar las predicciones a zonas de profundidades muy diferentes, ya que su exactitud cae considerablemente (ver Tabla 4.4: *RF-S(D)*, *SVM-S(D)*, *RF-D(S)*, *SVM-D(S)*, *RF-I(S)*, *SVM-I(S)*, *RF-I(D)*, *SVM-I(D)*).

En todos estos casos, el coeficiente de determinación  $R^2$  es negativo, lo cual indica que los modelos generan predicciones inadecuadas, donde incluso una línea horizontal explica

mejor los datos que los modelos obtenidos. Las predicciones de estos modelos se pueden observar en el gráfico de dispersión de la Figura 4.10. Por lo tanto, lo indicado es contar con un conjunto de datos que incluya todas las variaciones posibles del área de estudio para obtener modelos que puedan explicar todo el rango de variabilidad de profundidades del área, como en el caso de los modelos evaluados por transectas, sin que esto implique usar una cantidad excesiva de datos que tome más tiempo y sea más costoso registrar.

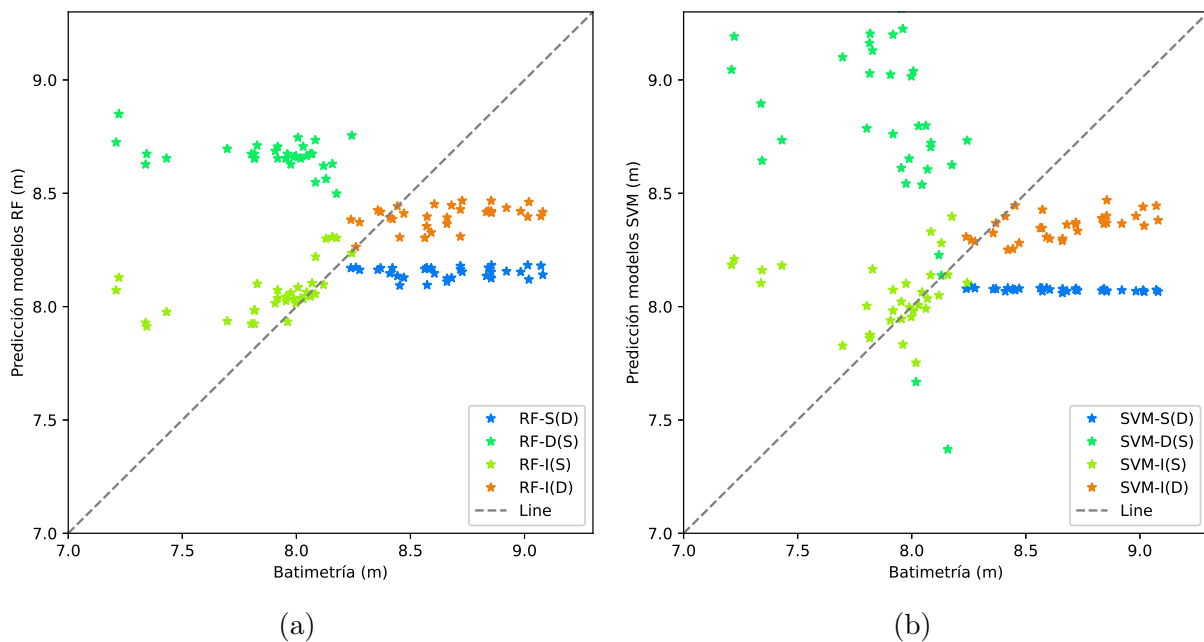


Figura 4.10: Profundidad predicha por los modelos batimétricos por zonas vs profundidad real para otras zonas. (D) Zona de mayor profundidad. (S) Zona de menor profundidad: (a) Bosques aleatorios (RF). (b) Maquinas de soporte vectorial (SVM).

#### 4.1.8. Estudio de ablación hiperespectral

Se llevó a cabo un análisis de ablación adicional para determinar la importancia relativa de las diferentes longitudes de onda en el modelo de Bosques Aleatorios. Los resultados muestran que hay pocas variables potencialmente confusas en el espectro visible (lejos del borde rojo). La Figura 4.11 muestra los resultados de importancia por permutación en las diferentes longitudes de onda utilizadas en el modelo.

**Tabla 4.5:** Precisión del modelo RF ( $R^2$ , RMSE, MAE) sobre el conjunto de validación, cuando se excluyen las bandas menos incidentes (560, 628, y 670 nm) y de mayor incidencia (698, 892, y 710 nm) a partir de las pruebas de permutación.

Métrica	Modelo de Bosques Aleatorios (RF)	
	Sin bandas menos incidentes	Sin bandas más incidentes
$R^2$	0.833	0.605
RMSE (m)	0.158	0.315
MAE (m)	0.118	0.197




Figura 4.11: Estudio de ablación hiperespectral sobre el modelo RF: Bandas más influyentes mediante la permutación de atributos, su importancia se muestra en orden ascendente. (a) Importancia por permutación sobre el conjunto de datos de validación. (b) Importancia por permutación sobre el conjunto de datos de entrenamiento.

La prueba de permutación sobre el conjunto de validación (Figura 4.11a) muestra que existen tres bandas confusas (560, 628, y 670 nm) que generan una disminución en la precisión del modelo. Al compararlas con la prueba de permutación para el conjunto de entrenamiento (Figura 4.11b), se encontró que este mismo conjunto de bandas solo genera una mejora marginal en el rendimiento del modelo y que, además, se encuentran entre las menos significativas para ambas pruebas. Por lo tanto, su omisión no tendrá un impacto notable en el rendimiento. Por otro lado, se evidencia en ambas pruebas que las bandas 698, 892, y 710 nm son las que mayor impacto generan sobre el modelo. Su omisión resultará en una notable degradación del rendimiento del modelo. En la Tabla 4.5

se puede observar el impacto sobre el rendimiento del modelo al omitir tanto el conjunto de bandas menos significativas como las de mayor importancia.

Otra prueba realizada al modelo RF consistió en evaluar la incidencia de cada uno de los atributos en el modelo (bandas espectrales) a través de las explicaciones aditivas de Shapley, las cuales conectan la asignación óptima de créditos con explicaciones locales utilizando los valores clásicos de la teoría de juegos y sus extensiones relacionadas (Lundberg and Lee, 2017). Los resultados para cada modelo pueden verse en las Figuras 4.12, donde los atributos más incidentes en el modelo se posicionan en la parte superior de la gráfica SHAP de forma descendente. Las pruebas incluyen todos los modelos previamente entrenados: para el área total, por transectas y por zonas. Los resultados muestran que, para los modelos de área total y por transectas, las tres bandas comunes más incidentes, ordenadas de mayor a menor, son 876, 705, y 870 nm. Para los modelos por zonas, las bandas comunes más incidentes son 892, 870, y 876 nm. En todos los casos, las bandas comunes son 870 y 876 nm. Sin embargo, de acuerdo al modelo evaluado las bandas tienen ponderaciones diferentes para todo el conjunto de bandas. Esto demuestra que la incidencia de las bandas depende del conjunto de datos de entrenamiento que este mapeando el rango de profundidades del área de estudio. Donde en función de esto, ciertas bandas pueden tomar más relevancia dentro del modelo.

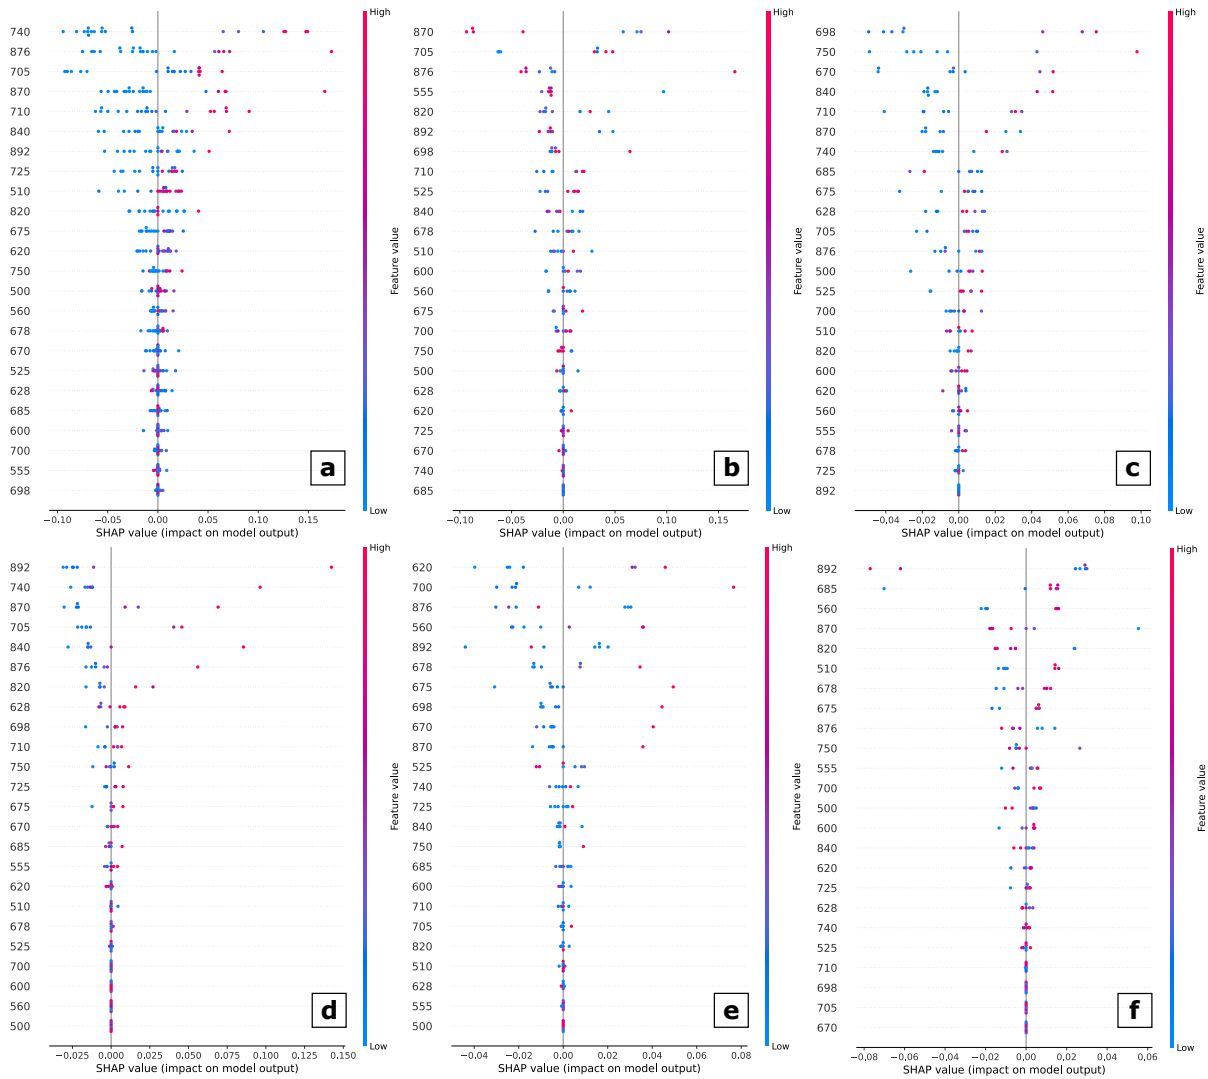


Figura 4.12: Gráficas SHAP de incidencia de las bandas espectrales para el modelo basado en bosques aleatorios (RF): (a)Modelo área total. (b) Modelo transectas AB. (c) Modelo transectas DE. (d) Modelo zona superficial. (e) Modelo zona intermedia. (f) Modelo zona profunda.

#### 4.1.9. Validación geomorfológica de los modelos batimétricos

Las cinco transectas de referencia registradas a través de la ecosonda Garmin por el vehículo EMAC-USV (ver Figura 4.3) fueron usadas para validar los modelos batimétricos RF y SVM. Además, se implementó el método de interpolación kriging (K) con el mismo conjunto de datos de entrenamiento de los modelos batimétricos. Así, se usaron tanto las predicciones del método kriging como los valores batimétricos de referencia para validar los modelos RF y SVM. Como primera muestra de validación, se tomó el punto más distante de la costa por cada transecta. Los resultados de esta validación se muestran en la Figura 4.13 y en la Tabla 4.6. Como era de esperarse, la profundidad disminuye a medida que se acerca a la costa en todas las transectas.

**Tabla 4.6:** Precisión de los modelos basados en bosques aleatorios (RF), máquinas de soporte vectorial (SVM) e interpolación kriging (K) en términos de  $R^2$ , RMSE y MAE sobre las transectas TA, TB, TC, TD y TE.

Métrica	Predicción transectas								
	TA(RF)	TA(SVM)	TA(K)	TB(RF)	TB(SVM)	TB(K)	TC(RF)	TC(SVM)	TC(K)
$R^2$	0.840	0.636	0.998	0.931	0.603	0.993	0.988	0.792	0.998
RMSE (m)	0.176	0.266	0.021	0.104	0.251	0.033	0.043	0.176	0.016
MAE (m)	0.123	0.202	0.010	0.084	0.190	0.016	0.034	0.143	0.008

Predicción transectas						
TD(RF)	TD(SVM)	TD(K)	TE(RF)	TE(SVM)	TE(K)	
0.910	0.776	0.975	0.955	0.710	0.981	
0.084	0.132	0.044	0.073	0.185	0.047	
0.062	0.124	0.011	0.055	0.161	0.020	

El mayor error de los modelos se encontró en la transecta TA, con un MAE y RMSE de 0.123 m y 0.176 m para el modelo RF, mientras que para el modelo SVM los errores registrados fueron de 0.266 m y 0.202 m respectivamente. Esta transecta influye significativamente en el rendimiento general de los modelos, donde se observa una tendencia a subestimar las profundidades mayores y sobrestimar las menores. No obstante, para las demás transectas, el rendimiento del modelo RF está por encima de las métricas de evaluación general, destacándose índices de determinación  $R^2$  de hasta 0.988 con bajas tasas de error. En cambio, el modelo SVM mantiene resultados similares a las métri-

cas de evaluación general en las otras transectas, presentando un menor rendimiento en comparación con el modelo RF.

Por otro lado, es notable el rendimiento del método de interpolación kriging, donde para todas las transectas evaluadas las tasas de error son muy bajas y presentan un  $R^2$  mayor a 0.970 para todos los casos. Si bien estos resultados indican que el método de kriging es superior en todas las transectas evaluadas, era de esperarse estos resultados, ya que los métodos de interpolación suelen tener bajas tasas de error para el conjunto de datos con los cuales se genera la interpolación, así como para los puntos circundantes que se tomen como validación. Sin embargo, suelen tener un rendimiento bajo para zonas de evaluación donde no existan puntos de referencia con los cuales se haya generado la interpolación y donde su estimación se basará en los puntos lejanos más cercanos.

Aunque el modelo RF mostró un buen rendimiento general, el método de kriging fue superior en términos de precisión para las transectas evaluadas. No obstante, es importante considerar las limitaciones del kriging en áreas sin puntos de referencia, donde las estimaciones se basan en puntos lejanos más cercanos. En estos casos, los modelos batimétricos basados en imágenes hiperspectrales pueden generar estimaciones más precisas, aprovechando la correlación entre la reflectancia espectral y la profundidad de la zona evaluada.






Figura 4.13: Validación de los modelos RF y SVM para las cinco transectas de referencia (se compara la predicción de los modelos con respecto a el método de interpolación kriging (K) y a las mediciones batimétricas).

Además, se llevó a cabo una validación geomorfológica trazando cinco transectos de prueba en la zona de estudio para evaluar la plausibilidad de los perfiles del fondo marino obtenidos. Cada transecto tiene una longitud aproximada de 18 m y una separación de aproximadamente 1.8 m (Figura 4.14), lo que corresponde a 500 píxeles a lo largo de la imagen hiperespectral. Los resultados de la batimetría prevista por los modelos basados en bosques aleatorios y máquinas de soporte vectorial se pueden observar en la Figura 4.15. Al comparar la predicción de cada modelo para la respectiva transecta, se hace evidente que el modelo RF presenta una mayor variabilidad a lo largo de toda la transecta, mientras que el modelo SVM genera una predicción más suave y uniforme. Esto indica que el modelo RF tiene una mayor sensibilidad ante los cambios de reflectividad presentes en la imagen hiperespectral, captando las pequeñas variaciones a lo largo de la transecta. En contraste, la predicción del modelo SVM puede asociarse a un suavizado de la predicción del modelo RF, que no logra representar las pequeñas variaciones del fondo marino.




Figura 4.14: Demarcación de las transectas de prueba para la evaluación geomorfológica de los modelos batimétricos.

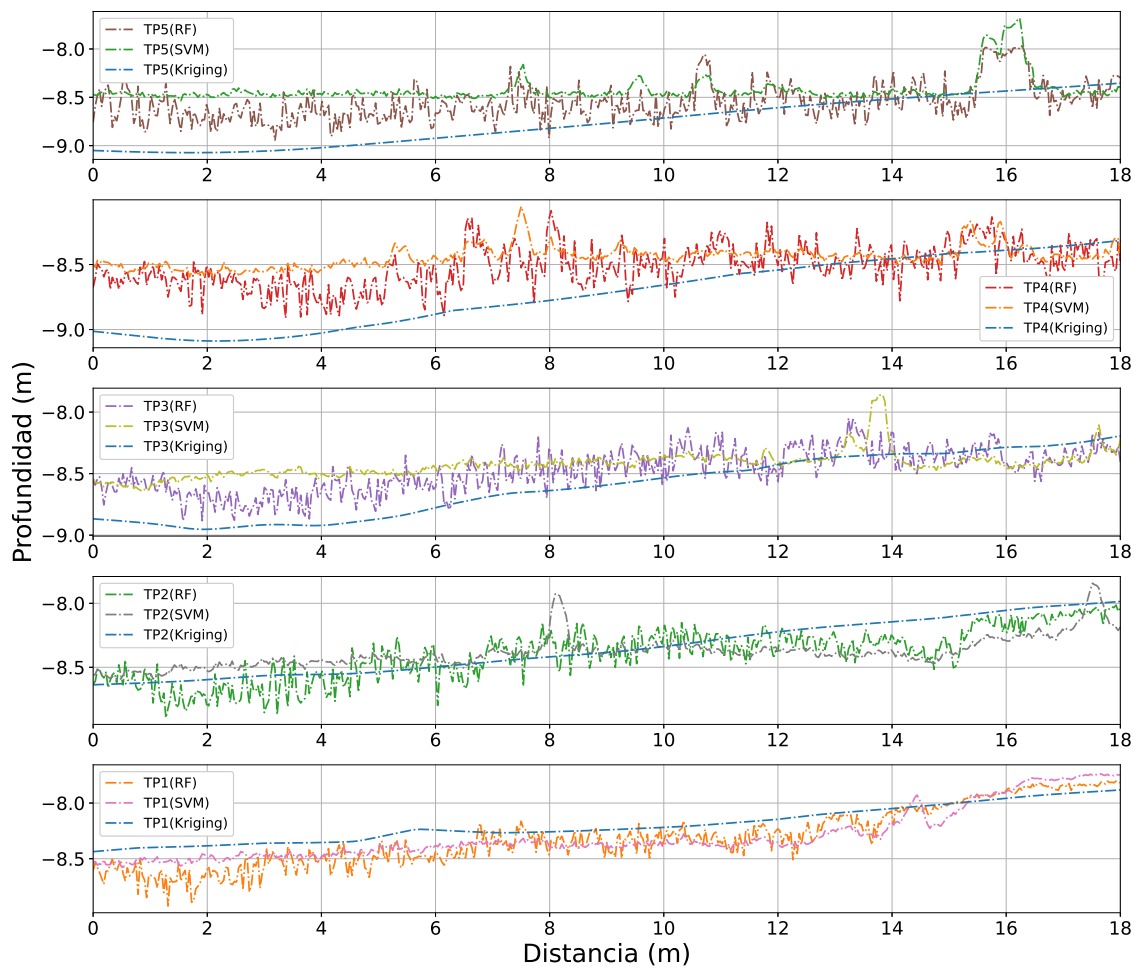


Figura 4.15: Perfiles previstos del fondo marino por los modelos de bosques aleatorios (RF), maquinas de soporte vectorial (SVM) e interpolación kriging (K) para las cinco transectas de prueba.

Al comparar los resultados de las Figuras 4.13 y 4.15, se observa una gran diferencia en cuanto a la geomorfología que describe cada perfil. Aunque no coinciden exactamente en su geolocalización, están muy próximas entre ellas. Esta diferencia se debe en gran medida a que las transectas de referencia solo tienen 20 mediciones a lo largo de cada transecto (Figura 4.3) y pueden representar la profundidad en esos puntos específicos (Figura 4.13), resultando en una interpolación de primer grado entre estos puntos.

En contraste, la predicción de las transectas de prueba por parte de los modelos batimétricos (Figura 4.14) describe la profundidad en 500 puntos o píxeles provenientes

de la imagen hiperspectral, lo que permite describir la forma del fondo con una resolución espacial de 3.5 cm por píxel (Figura 4.15), aproximadamente 25 veces mayor que la resolución espacial de las mediciones batimétricas de cada transecta.

Por otro lado, el método de interpolación kriging presenta una estimación muy suave a lo largo de todas las transectas, mostrando diferencias notables con respecto a los modelos batimétricos en cuanto a los valores de profundidad, que pueden superar los 0.5 m en algunos casos (ver Figura 4.15). Dado que la estimación de las transectas se hizo para un valor de 500 puntos en un rango de aproximadamente 18 m a una resolución de aproximadamente 3.5 cm, no es de esperar que la forma del fondo presente una forma tan suave sin casi ninguna variación, excepto por la pendiente que muestra cómo la profundidad disminuye a medida que se aproxima a la costa. Mientras que por otro lado, el modelo RF muestra una rugosidad en el orden de centímetros a lo largo de toda la transecta, lo cual es más coherente con la forma real del fondo marino. Esto muestra cómo el método de kriging genera estimaciones suaves basadas en los puntos más cercanos, lo que limita su capacidad para representar variaciones reales en la superficie subacuática a menos que se utilice una muestra más densa de datos del área de estudio. Por otro lado, los modelos batimétricos basados en imágenes hiperspectrales pueden capturar estas variaciones con mayor precisión, dada la resolución espacial de la imagen, aprovechando la relación existente entre la reflectancia captada y la profundidad del cuerpo de agua, utilizando un menor número de mediciones batimétricas para representar el rango de profundidad del área de estudio.

Estas diferencias destacan la capacidad de los modelos de aprendizaje maquina como RF y SVM para representar la rugosidad y las variaciones del fondo marino con mayor precisión, en comparación con métodos de interpolación tradicionales como kriging. Los resultados de los modelos RF y SVM reflejan de manera más realista las características del fondo marino, lo que es crucial para aplicaciones que requieren un detalle fino de la batimetría, como la navegación, la gestión costera y la investigación científica.

#### 4.1.10. Batimetría densa del área de estudio

El mejor modelo encontrado, basado en el algoritmo de bosques aleatorios, se aplicó a la imagen hiperespectral completa, asignando una batimetría a cada píxel de la imagen a partir de los 24 valores correspondientes de las bandas espectrales. Se aplicó una máscara para excluir el muelle, el borde de la costa y el barco de la imagen, obteniendo así una reconstrucción densa ( $1024 \times 648$  píxeles) con una resolución espacial de 3.6 cm por píxel. La imagen resultante contiene todos los valores de profundidad asociados para el agua, y para los objetos excluidos, tiene un valor nulo. Gracias a esto, fue posible generar un mapa de contornos sobre la imagen con el software Surfer 8, sin necesidad de emplear ningún método de interpolación, dado que se tienen todos los valores para la malla de referencia que utiliza el software (Figura 4.16). La profundidad se observa en función de un rango de colores y la forma del fondo a través del mapa de contornos de la zona de estudio.




Figura 4.16: Batimetría densa del área de estudio basado en imágenes hiperespectrales aéreas y mediciones de ecosonda a bordo del vehículo EMAC-USV.

## 4.2. Batimetría de alta resolución en zonas costeras turbias a partir de imágenes satelitales hiperspectrales

En este apartado se detalla una metodología innovadora que permite obtener batimetrías de alta resolución mediante la fusión de imágenes satelitales hiperspectrales con una imagen pancromática de alta resolución y datos batimétricos dispersos en una zona costera de aproximadamente 4000 km<sup>2</sup>. Al igual que en el estudio previo (sección 4.1), el propósito principal es evaluar la viabilidad de obtener una batimetría de alta resolución útil mediante esta fusión en una extensa área de estudio. Los datos batimétricos se obtuvieron de una carta náutica, utilizada como referencia para entrenar modelos de regresión basados en bosques aleatorios. Estos modelos, como se demostró en la investigación anterior, son capaces de predecir la profundidad real con menor error en función de los valores digitales de las bandas espectrales.

La resolución pancromática de las imágenes hiperspectrales se logró mediante el método de fusión pancromática basado en PCA, lo que generó un nuevo conjunto de datos hiperspectrales. Este conjunto se utilizó para entrenar diversos modelos, los cuales se compararon con el mismo enfoque utilizando el conjunto de imágenes predeterminado del satélite. Se validó un método para identificar las bandas más influyentes en los modelos, lo que permitió obtener un modelo optimizado con un menor número de bandas y un mejor rendimiento. Para validar los modelos obtenidos, se realizó una comparación con la interpolación kriging, uno de los métodos convencionales más utilizados y precisos para generar mapas a partir de puntos georreferenciados dispersos. La validación se llevó a cabo mediante una transecta de validación y una captura hiperspectral del área de estudio.

Finalmente, Los mejores modelos optimizados se aplicaron al conjunto de capturas hiperspectrales disponibles para obtener una batimetría de alta resolución del área de estudio a dos resoluciones espaciales 30 m y 5 m por píxel. En la Figura 4.17 se ilustra un

diagrama que contiene las dos etapas principales de la metodología (Procesado de datos y Entrenamiento y evaluación de los modelos).

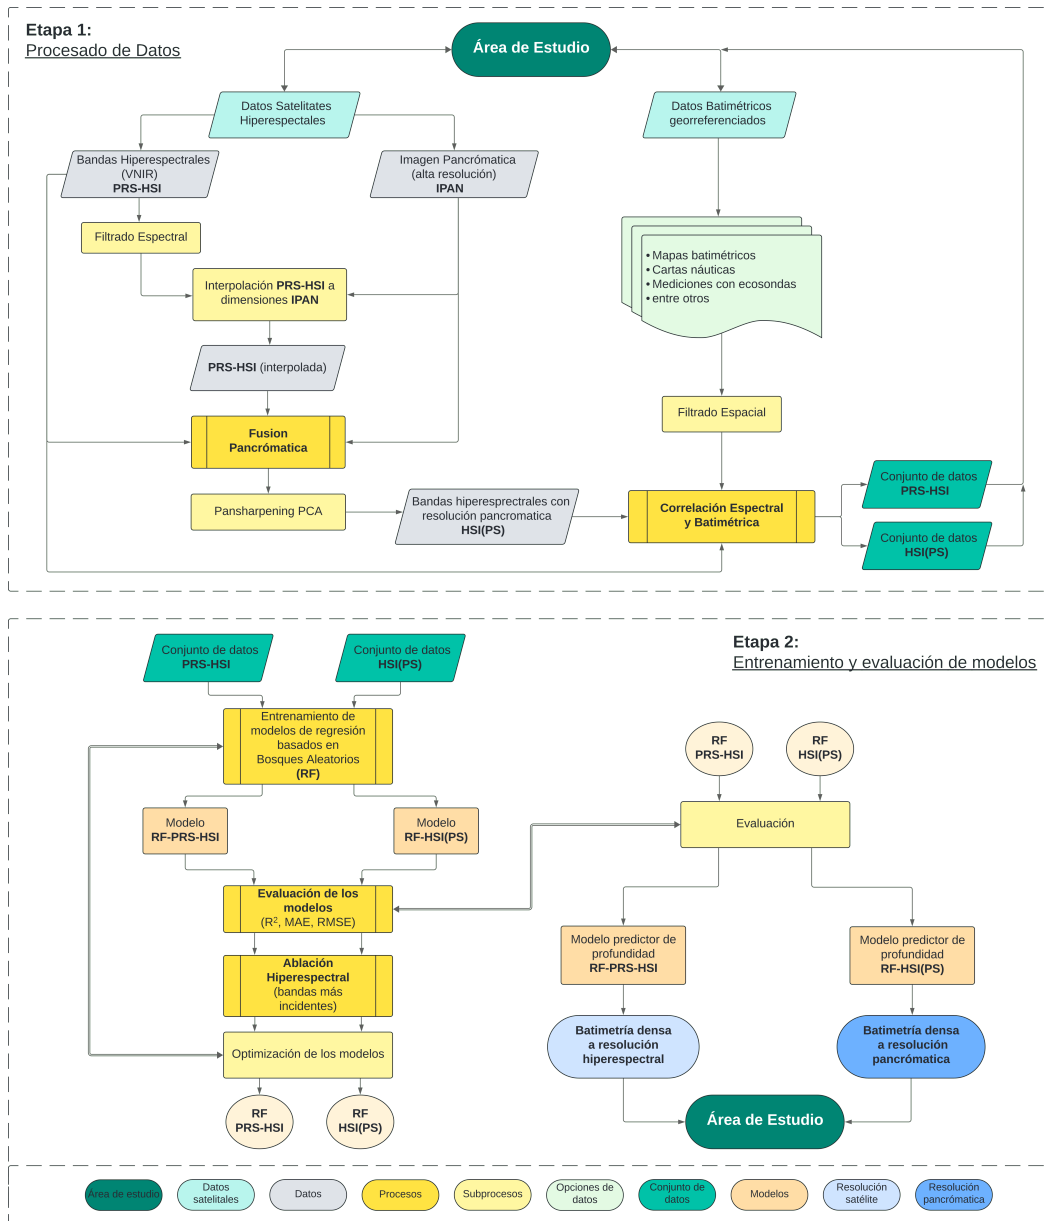


Figura 4.17: Batimetría satelital hiperspectral: Metodología para obtener batimetrías de alta resolución a partir de la fusión de imágenes satelitales y datos batimétricos.



### 4.2.1. Área de estudio

El área de estudio, conocida como la Bahía Samborombón, se encuentra ubicada al noreste de la provincia de Buenos Aires, en la desembocadura del Río de la Plata, en el tramo donde éste se encuentra estuarialmente con el mar argentino (Figura 4.18).




Figura 4.18: Área de estudio: Bahía Samborombón (marcada en la zona central), Punta Rasa (enmarcada en la zona inferior derecha). Fuente: Áreas Costeras y Marinas Protegidas de la Argentina ([AMP](#)).

Esta región abarca una línea costera de aproximadamente 180 km y, desde una perspectiva geomorfológica, constituye el límite oriental de una extensa área de alrededor de 58000 km<sup>2</sup> conocida como la Pampa deprimida. El clima en la zona es templado-húme-



do, con vientos predominantes del este. La vegetación predominante es de naturaleza herbácea, a excepción de las comunidades establecidas sobre los cordones de conchillas. La influencia de las mareas resulta en la entrada de agua salobre, mientras que los ríos, canales y arroyos aportan agua dulce, dando lugar a un sistema hidrológico complejo con una gran variedad de humedales ([Bahía Samborombón \(Buenos Aires y APN\), 2020](#)). Estos ecosistemas se ven directamente afectados por los cuerpos de agua circundantes, que generan procesos erosivos que transportan sedimentos, resultando en aguas turbias a lo largo de toda la Bahía, especialmente en la desembocadura del Río de la Plata. Esta zona costera, junto con la costa sur de la provincia de Buenos Aires, es un área de interés para estudios costeros. Por ejemplo, [Bacino et al. \(2019\)](#) ha estudiado los cambios en el clima de olas y su impacto en la erosión costera en la Bahía de Samborombón. Otra investigación más reciente desarrollada por [Bacino et al. \(2023\)](#) estudia la evolución morfológica de una playa protegida por escollera en Mar del Plata (Provincia de Buenos Aires), utilizando un UAV y fotogrametría para reconstruir la morfología y aplicar índices SPI y SEPI para analizar la respuesta de la playa a tormentas costeras, destacando una relación lineal entre los cambios morfológicos y las variables oceanográficas.

#### 4.2.2. Datos batimétricos

Los datos batimétricos de referencia utilizados para la Bahía Samborombón consisten en un mapa batimétrico georreferenciado proporcionado por el Servicio de Hidrografía Naval de la Armada Argentina. Este mapa (carta náutica) contiene cientos de puntos de profundidad (en metros) que abarcan toda la extensión de la Bahía Samborombón. Para extraer estos puntos de profundidad, se empleó el software QGIS, que es un sistema de información geográfica de código abierto. QGIS permitió cargar el mapa de referencia y corregirlo espacialmente con el mapa geográfico de Google Earth (Figura 4.19). Una vez que el mapa estuvo correctamente corregido, se creó una nueva capa en QGIS con geometría de puntos, donde se indexaron las coordenadas geográficas y la profundidad




Figura 4.19: Mapa batimétrico de referencia georreferenciado de la Bahía Samborombón. para cada punto deseado sobre el mapa de referencia. Todos los puntos disponibles que estaban correlacionados geográficamente con los datos hiperspectrales seleccionados del satélite PRISMA fueron marcados (ver Figura 4.21). Para cada punto marcado, se registró la profundidad junto con la coordenada geográfica correspondiente, obteniendo así un conjunto de 900 puntos de profundidad debidamente georreferenciados en un archivo de texto plano. La Figura 4.20 muestra la distribución de los puntos marcados en el mapa batimétrico.

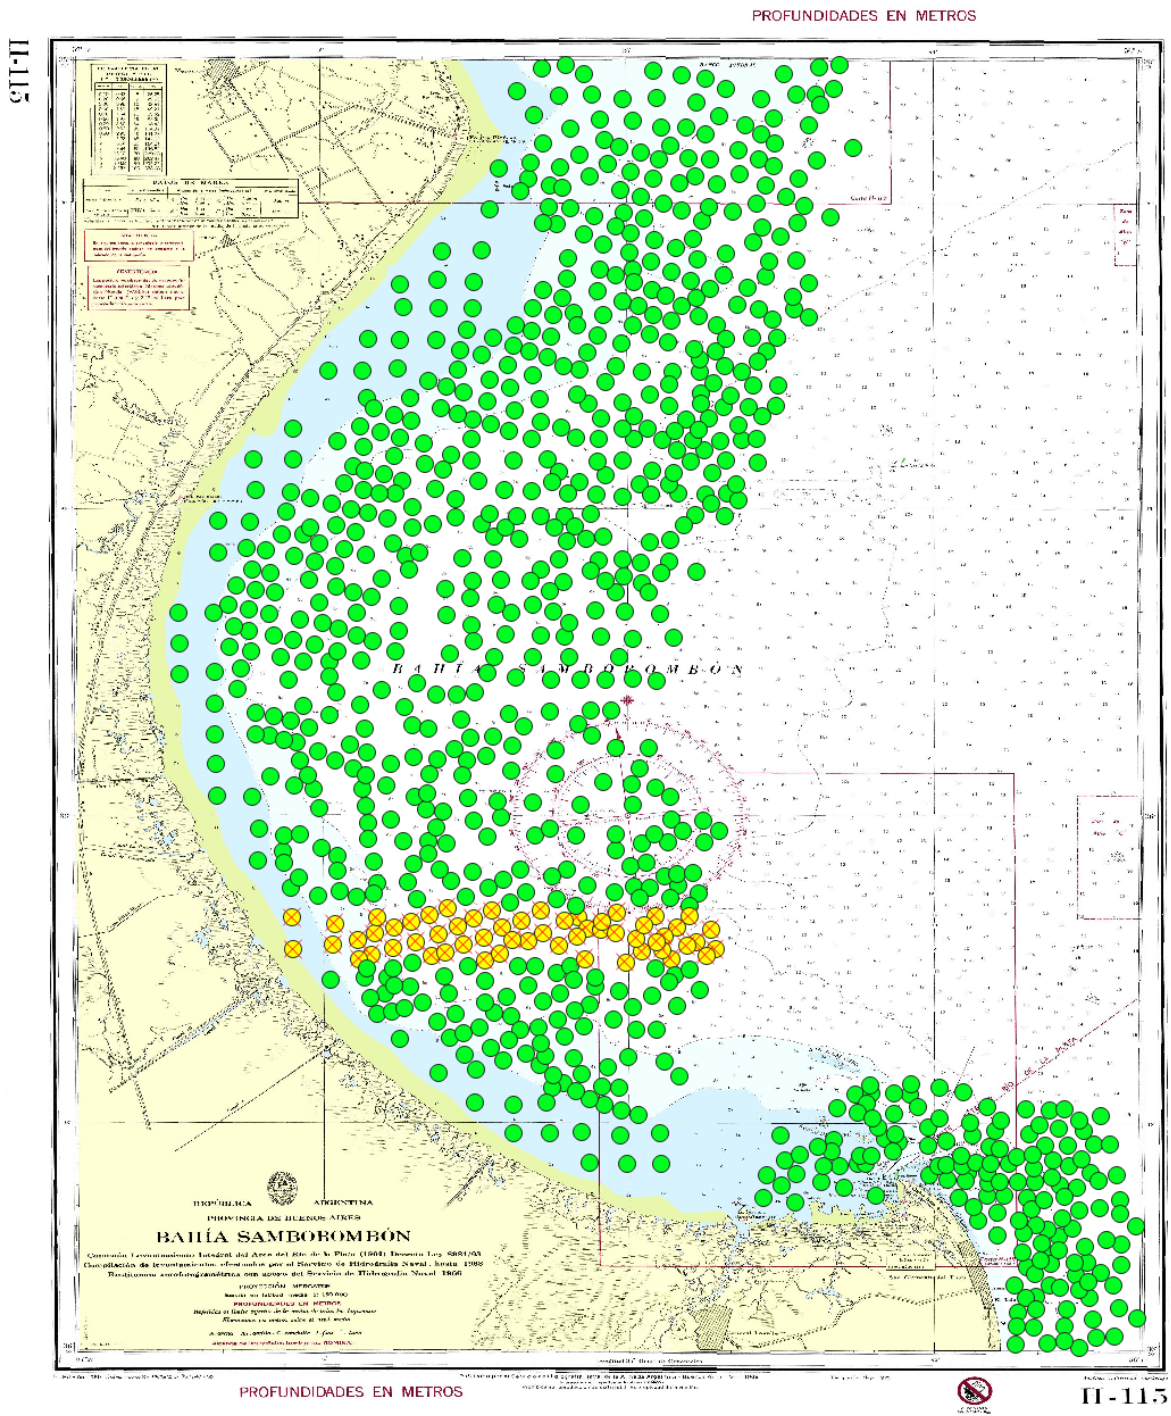


Figura 4.20: Puntos batimétricos georreferenciados (en color amarillo se marcaron los puntos que serán usados como transecta de validación).

### 4.2.3. Datos satelitales hiperspectrales

Las imágenes hiperspectrales (HSI) empleadas en este estudio provienen del satélite hiperspectral PRISMA (PRISMA, 2019), lanzado a órbita en marzo de 2019 por la Agencia Espacial Italiana (ASI). PRISMA, con un período de muestreo de 30 días, está equipado con un generador de imágenes hiperspectrales (PRISMA HIS) capaz de adquirir imágenes con una resolución de  $1222 \times 1195$ , con una huella de píxel de 30 m, cubriendo áreas de  $900 \text{ km}^2$ . Su resolución espectral es inferior a 12 nm, con un total de 239 bandas. De estas, las primeras 66 bandas abarcan el espectro visible e infrarrojo cercano (VNIR) con un rango espectral de 400 a 1010 nm, mientras que las restantes 173 bandas se encuentran en el rango infrarrojo de onda corta (SWIR) con un espectro de 920 a 2500 nm. Además de las HSI, el satélite PRISMA proporciona una imagen pancromática (IPAN) de alta resolución, con una resolución espacial de 5 m por píxel. Mediante técnicas de Pansharpening (PS), la resolución espacial de las HSI se puede mejorar a  $5 \text{ m} \times 5 \text{ m}$ , lo que facilitaría la detección y mapeo de objetos más pequeños en la superficie terrestre, y a su vez permitiría construir modelos batimétricos de mayor resolución basados en HSI.

Las HSI utilizadas en este estudio fueron capturadas por el satélite PRISMA el 03 de marzo de 2020 y el 24 de agosto de 2020, en condiciones de cielo despejado y con una presencia de nubes inferior al 10 %. Estas imágenes fueron adquiridas en la Bahía Samborombón (ver Figura 4.18). El conjunto de datos hiperspectrales consta de 234 bandas (400-2500 nm) con una resolución espacial de 30 m, además de una IPAN (400-700 nm) con una resolución espacial de 5 m, la cual está coregistrada con los datos hiperspectrales, permitiendo la evaluación de técnicas de fusión de imágenes o PS.

Con base en la información batimétrica disponible del área de estudio (ver Figura 4.19), se realizó el mapeo de los datos hiperspectrales proporcionados por el satélite PRISMA. De un total de 13 datos hiperspectrales disponibles, ubicados dentro del polígono que abarca la información batimétrica en un área de aproximadamente  $4000 \text{ km}^2$ , se seleccionaron 9 datos hiperspectrales, eliminando aquellos redundantes correspondientes a un

período de captura diferente al del conjunto de datos seleccionado o que presentaban un mayor porcentaje de nubosidad. En la Figura 4.21 se muestran las capturas seleccionadas que cubren alrededor de las dos terceras partes del polígono marcado, cubriendo una superficie de más de 4000 km<sup>2</sup>.




Figura 4.21: Capturas hiperspectrales del satélite PRISMA en el área de estudio. Se destacan en color las siguientes capturas: (a) Captura interna de la Bahía Samborombón. (b) Captura ubicada en Punta Rasa (ver Figura 4.18).

Tal y como se menciona en la sección 2.3.1 el rango de bandas VNIR tiene una mayor capacidad de penetración en las masas de agua, mientras que la reflectividad en las bandas SWIR no es tan evidente, y considerando además que la IPAN está registrada dentro del



rango VNIR, en este estudio se optó por utilizar únicamente las bandas VNIR (66 en total) junto con la IPAN como conjunto de imágenes hiperespectrales. En la Figura 2.3 se puede observar el rango espectral que cubre tanto las bandas VNIR como SWIR. Si bien la capacidad de penetración de las bandas VNIR depende de varios factores como la presencia de sedimentos en el agua, materia orgánica disuelta, entre otros. Estimaciones indican que es posible registrar profundidades de hasta 30 m en aguas claras (Mobley, 1994; Lee et al., 2002; Dekker et al., 2005), disminuyendo su profundidad en función de la materia orgánica e inorgánica presente en el agua (Kirk, 2010; Matthews, 2011).

En la Figura 4.22 puede observarse la diferencia de resolución espacial entre la imagen pancromática y una de las bandas del conjunto de datos hiperespectral cuando se realiza una vista ampliada sobre una región de la imagen. La zona observada corresponde a una región al sureste de la Bahía Samborombón denominada Punta Rasa (ver Figuras 4.18 y 4.21).

#### 4.2.4. Procesado de datos

En este apartado se presentan las diferentes fases contempladas en la etapa 1 del diagrama de flujo de la metodología propuesta (ver Figura 4.17). El procesado de los datos así como el entrenamiento, optimización y predicción de los modelos descritos en las siguientes secciones se llevaron a cabo en un computador personal equipado con un procesador Intel(R) Core(TM) i7-12700H, 2.30 GHz con 32 Gb de memoria RAM.

##### Filtrado espectral

El filtrado espectral consiste en determinar si existen bandas espectrales dentro del conjunto de datos HS que tengan un alto nivel de ruido o que simplemente sean bandas nulas sin ningún tipo de información espectral. Para esto se hizo uso de la ecuación 4.4 que representa el índice relación señal a ruido (SNR), donde  $P_{imagen}$  representa la potencia de

la imagen que se obtiene mediante la varianza ( $\sigma^2$ ) de la imagen y  $P_{ruido}$  como la varianza del ruido.

$$SNR_{dB} = 10 * \log_{10} \left( \frac{P_{imagen}}{P_{ruido}} \right) \quad (4.4)$$

Basado en los resultados del  $SNR$  para cada una de las bandas, se identificaron las bandas cuyo  $SNR$  es menor al conjunto de datos. Se eliminaron del conjunto de datos espectrales aquellas bandas que mostraron un bajo índice de relación señal a ruido (ecuación (4.4)), resultando en un conjunto de HSI de 63 bandas. Las bandas eliminadas corresponden al rango (979 - 1010 nm).




Figura 4.22: Visualización de datos del satélite PRISMA sobre la captura de la Figura 4.21b, (Vista alejada y ampliada): (a, c) Banda hiperespectral (716 nm) (30 m por píxel). (b, d) Imagen pancromática (5 m por píxel).

## Pansharpening PCA

El método de pansharpening PCA (PS-PCA) requiere que tanto el conjunto HSI como la IPAN tengan las mismas dimensiones. Dado que el conjunto HSI tiene una dimensión de  $1222 \times 1195$  píxeles, mientras que la IPAN tiene una resolución 36 veces mayor. Se requiere igualar las dimensiones del conjunto HS con las de la IPAN, para lo cual se aplicó una interpolación spline de tercer orden a todas las bandas del conjunto HS. La implementación de la interpolación spline se realizó haciendo uso de la librería Scikit-image Python ([van der Walt et al., 2014](#)). Esto resultó en un nuevo conjunto de imágenes hiperespectrales interpolado (HSI-interpolado) (ver ecuación 2.1) con una dimensión de  $7232 \times 7170$  píxeles que coincide con la resolución de la IPAN.

La implementación de PS-PCA se realizó siguiendo la metodología presentada en la Figura 2.5, los pasos descritos en la sección 2.4.1 y las ecuaciones 2.1 y 2.2 mediante el uso de la librería para cálculo numérico Numpy-Python. El método PS-PCA fue aplicado a todo el conjunto de imágenes HSI-interpolado, tomando como referencia la IPAN-PRISMA para cada conjunto de datos HS descritos en la Figura 4.21, lo cual generó un nuevo conjunto de imágenes hiperespectrales con una mayor resolución espacial (HSI(PS)) de 5 m por píxel que contrasta con el conjunto PRS-HSI original de solo 30 m por píxel.

El tiempo de ejecución por captura hiperespectral requerido para procesar el método PS-PCA es de aproximadamente 26 minutos para generar un conjunto de datos HSI(PS) con dimensiones  $7232 \times 7170 \times 63$  usando la computadora personal descrita en la sección 4.2.4. En la Figura 4.23 se puede observar la comparación de una imagen HSI-PRISMA y el resultado de PS-PCA a diferentes distancias. En las vistas con mayor nivel de acercamiento (Figura 4.23 I(b), II(b) y I(c), II(C)) se evidencia que el nuevo conjunto de datos HSI(PS) tiene mayor resolución espacial (5 m por píxel) con bajos niveles de distorsión. En la Figura 4.24 se puede observar el espectro de reflectancia para diferentes puntos de profundidad del área de estudio del conjunto PRS-HSI comparado contra HSI(PS) obtenido a partir de pansharpening.






Figura 4.23: Visualización de la banda 628 nm sobre la captura de la Figura 4.21b en resolución PRISMA (PRS-HSI) y Pancromática (HSI(PS)). Vistas a diferentes distancias: I(a, b, c) PRS-HSI (30 m por píxel). II(a, b, c) HSI(PS) (5 m por píxel).

## Correlación espectral y batimétrica

Basado en las coordenadas geográficas del conjunto de datos batimétricos (Figura 4.20), se registraron y correlacionaron 900 puntos con cada uno de los conjuntos de datos PRS-HSI y HSI(PS) respectivamente. De estos, 30 puntos quedaron fuera del conjunto de datos final, ya que se encontraban fuera de las coordenadas geográficas de las HSI. Esto se debe a que, dada la disponibilidad de datos PRISMA, hay áreas entre los conjuntos de datos HSI donde no hay datos HSI disponibles (ver Figura 4.21).

De esta manera, se generaron dos conjuntos de datos de  $870 \times 67$ . Cada fila corresponde a un registro que contiene un identificador HSI (ID), las coordenadas en latitud y longitud, los números digitales de cada una de las 63 bandas espectrales y la profundidad respectiva para ese punto. En la Tabla 4.7 se muestra una vista reducida de uno de los conjuntos de datos conformados (PRS-HSI).

**Tabla 4.7:** Coordenadas geográficas, longitudes de onda hiperspectrales, números digitales, y profundidades para cinco puntos aleatorios del conjunto PRS-HSI.

ID	Geolocalización		Banda Espectral (nm)					Profundidad (m)
	Latitud	Longitud	979	958	...	419	400	
PRS-20200824135933	-35.978201	-57.217610	435	487	...	8451	9527	5.9
PRS-20200824135925	-35.411308	-56.863218	177	64	...	5837	6865	4.9
PRS-20200824135933	-35.909210	-57.219159	208	18	...	6615	10508	7.2
PRS-20200824135925	-35.464184	-56.894192	214	118	...	6292	6987	5.8
PRS-20220413135340	-36.046993	-56.947721	310	54	...	4547	5936	10.0

Para cada conjunto de datos conformado (PRS-HSI y HSI(PS)) se tomaron los puntos de profundidad menor, media y mayor con los cuales se trazó la firma espectral para cada uno de estos puntos. La reflectancia espectral para el rango de profundidades del área de estudio se puede observar en la Figura 4.24. Los resultados muestran que cada profundidad tiene una firma espectral distintiva, lo cual confirma que los números digitales de cada banda espectral servirán como un buen descriptor de la profundidad. Al comparar la firma espectral para un mismo punto de profundidad de ambos conjuntos PRS-HSI y HSI(PS), se puede ver que la reflectancia se atenuó para el conjunto de datos HSI(PS) a lo largo de todo el espectro VNIR y se hizo cero cerca de los 900 nm para la profundidad menor y

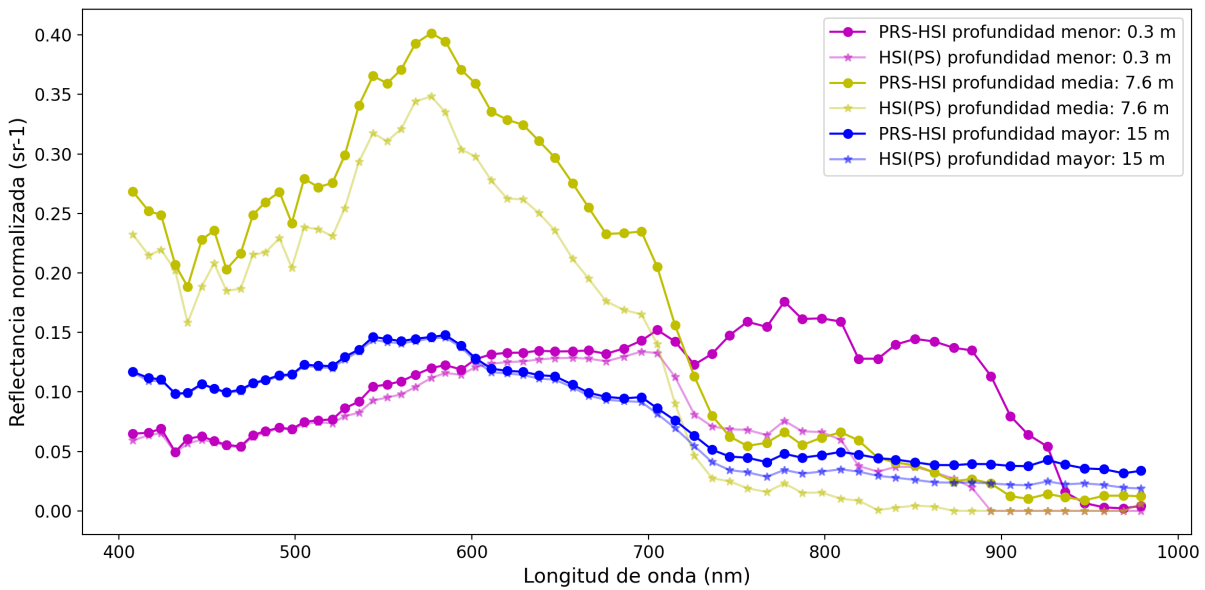


Figura 4.24: Espectro de Reflectancia VNIR para los puntos de profundidad menor, media y mayor de los conjuntos hiperespectrales PRS-HSI y HSI(PS).

media. Esto se debe al refinado pancromático obtenido a partir del conjunto hiperespectral PRS-HSI y de la imagen pancromática respectiva (registrada en el rango espectral entre los 400 y 700 nm por el satélite PRISMA), que permitió obtener un nuevo conjunto con la resolución IPAN (5 m por píxel). Además de tener mayor resolución espacial, el conjunto de datos HSI(PS) adquirió características espectrales de la IPAN, que se ven reflejadas en la reflectancia espectral del conjunto de datos HSI(PS).

#### 4.2.5. Entrenamiento de los modelos

En esta sección se presentan las fases correspondientes a la etapa 2 de la metodología presentada en la Figura 4.17. Los modelos de regresión de bosques aleatorios (RF) fueron entrenados con el conjunto de datos previamente descrito, utilizando los 63 valores (números digitales) de las bandas espectrales como variables explicativas y el valor de profundidad de referencia como variable explicada. Se utilizó la implementación estándar de la biblioteca Scikit-Learn de Python (Pedregosa et al., 2011). La afinación de hiperparámetros se llevó a cabo mediante RandomizedSearchCV, usando validación cruzada

k-fold con  $k = 5$ . De todo el conjunto de datos se extrajeron 57 puntos que conforman la transecta de testeo marcados en color amarillo en la Figura 4.20. El entrenamiento se realizó con el conjunto de puntos restante (813 puntos) con la partición del 80 %, 20 %, para entrenamiento y validación, respectivamente, con el fin de evitar el sobreajuste.

#### 4.2.6. Resultados del entrenamiento y evaluación de los modelos

El mejor modelo de bosques aleatorios (RF) y la iteración con el conjunto de prueba (datos no vistos por el modelo) obtuvo con un error cuadrático medio (RMSE) de 1.170 m y un coeficiente de determinación  $R^2 = 0.845$ . El error absoluto promedio (MAE) de RF fue de 0.910 m, para el conjunto de datos PRS-HSI. Por otro lado, para el conjunto de datos HSI(PS) se obtuvo un RMSE de 1.148 m, un  $R^2 = 0.859$  y un MAE de 0.830 m (ver ecuaciones. 4.1, 4.2, 4.3). Los resultados se pueden observar en las Tabla. 4.8.

**Tabla 4.8:** Precisión de los modelos basados en bosques aleatorios (RF) para el conjunto validación ( $R^2$ , RMSE, MAE).

Métrica	Conjunto de Datos	
	PRS-HSI	HSI(PS)
$R^2$	0.845	0.859
RMSE	1.170	1.148
MAE	0.910	0.830

El modelo RF con el conjunto de datos HSI(PS) presenta un rendimiento superior (en términos de  $R^2$ , error cuadrático medio, y error absoluto promedio) en comparación con el modelo basado en el conjunto de datos PRS-HSI. En la Figura 4.25(a, b), se presenta un gráfico de dispersión de la predicción del modelo RF con respecto a la batimetría de referencia para el conjunto de datos de entrenamiento y validación de PRS-HSI y HSI(PS) respectivamente. El ajuste lineal de los modelos tiene una pendiente de 1.011 para PRS-HSI y 1.045 HSI(PS) respectivamente, con los datos de validación. Para el modelo RF del conjunto PRS-HSI solo se identificaron cinco valores atípicos, mientras que para el modelo RF-HSI(PS) diez puntos fueron identificados con un error absoluto mayor a 2.25 m (Figura 4.25(c, d)).

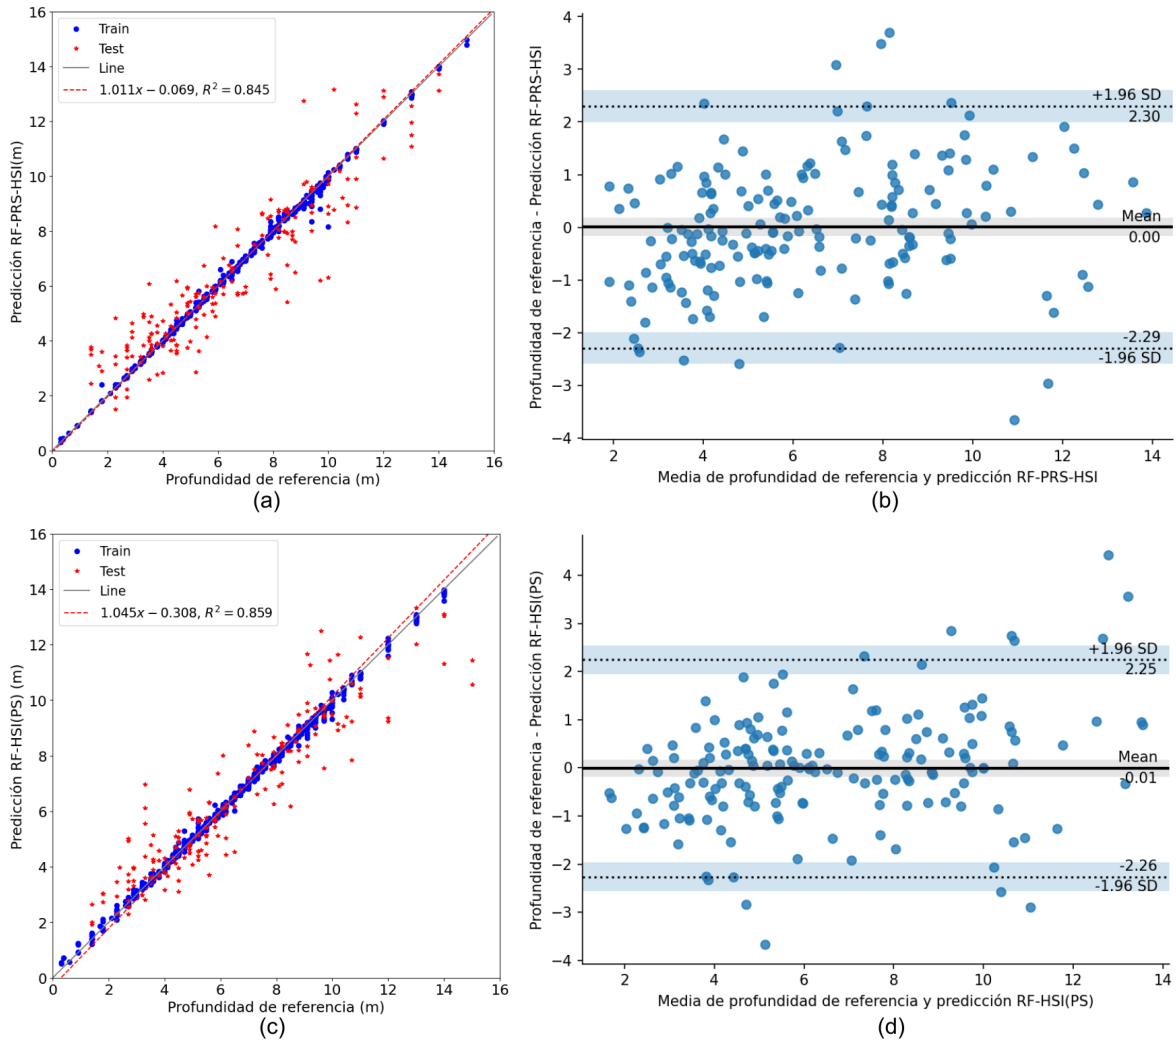


Figura 4.25: Resultados de los modelos batimétricos basados en bosques aleatorios (RF) (Profundidad estimada frente a profundidad de referencia en el entrenamiento y la validación de los modelos, y diagrama de Bland-Altman): (a, b) RF-PRS-HSI. (c, d) RF-HSI(PS).

#### 4.2.7. Estudio de ablación hiperspectral

Se realizó un análisis de ablación para determinar la contribución de cada banda espectral en los modelos, utilizando las explicaciones aditivas de Shapley. Estas explicaciones vinculan la asignación óptima de créditos con explicaciones locales, empleando los valores clásicos de la teoría de juegos y sus extensiones relacionadas (Lundberg and Lee, 2017). Gracias a lo cual, se pueden explicar los resultados de los modelos de aprendizaje automático. El método SHAP (SHapley Additive exPlanations) ofrece una comprensión de cómo cada atributo afecta al modelo, posibilitando análisis tanto locales como globales para el conjunto de datos. En los modelos lineales y de árboles de decisión, los coeficientes suelen utilizarse como métrica para evaluar la importancia global de un atributo, pero no están normalizados según la escala de la variable, lo que puede inducir distorsiones e interpretaciones erróneas. Además, los coeficientes no pueden capturar la importancia local del atributo y cómo ésta varía con valores más bajos o altos (Merrick and Taly, 2020). Por consiguiente, SHAP resulta útil para la interpretación de los modelos. Los resultados del método SHAP para cada modelo se presentan en la Figura 4.26, donde los atributos más influyentes en el modelo se muestran en la parte superior del gráfico SHAP, ordenadas de manera descendente.

Los resultados para los veinte atributos más influyentes (Figura 4.26(a, c)) muestran que en el modelo RF-PRS-HSI, el rango de bandas abarca desde 676 hasta 969 nm, siendo la banda de 840 nm la más influyente. Por otro lado, el modelo RF-HSI(PS) presenta un rango de bandas entre 417 y 726 nm, siendo la banda de 696 nm la más influyente con un factor SHAP medio absoluto de 0.33, en comparación con 0.23 para la banda más influyente del otro modelo. Esta diferencia en los rangos espectrales de cada modelo se puede atribuir en parte al efecto de la fusión pancromática (PS-PCA) realizada, donde la imagen pancromática proporcionó información espacial al nuevo conjunto de datos, basada en su rango espectral que se encuentra entre los 400 y 700 nm, coincidiendo con el rango espectral de las veinte bandas más influyentes en el modelo RF-HSI(PS).

Al analizar la suma de los valores SHAP medios absolutos para cada banda de los dos modelos de Random Forest (RF), se observa que en el modelo RF-HSI(PS), las bandas tienen una influencia más marcada en la predicción, con un valor de 4.49 en comparación con 4.12 del modelo RF-PRS-HSI. Además, al considerar la suma de los valores SHAP medios absolutos para las veinte bandas más influyentes en el modelo (Figura 4.26(b, d)), se obtiene un valor de 2.96 para el modelo RF-HSI(PS), mientras que para el otro modelo es de 2.16. Esto sugiere que el modelo RF-HSI(PS) podría tener un mejor rendimiento con este conjunto de bandas en comparación con el modelo basado en el conjunto PRISMA.

Asimismo, al observar la relevancia de las 43 bandas restantes (Figura 4.26(b, d)), se observa que esta es mayor en el modelo RF-PRS-HSI, lo que indica que este último requiere un mayor número de bandas para lograr una respuesta equivalente al modelo RF-HSI(PS).

#### 4.2.8. Optimización de los modelos

Basados en los resultados de los atributos más incidentes en los modelos, obtenidos mediante los valores SHAP, se realizó un reentrenamiento de los modelos. En cada prueba, se fue reduciendo el número de bandas espectrales (atributos) según el criterio de importancia global de incidencia. Se mantuvieron las bandas espectrales que más contribuyeron a la predicción del modelo, de acuerdo con un factor de evaluación que varía entre 0 y 1. Un factor de 1 corresponde al modelo con todo el conjunto de bandas (63 bandas), mientras que, por ejemplo, un factor de 0.7 incluye el número de bandas más incidentes que permiten obtener el 70% de la suma de los valores SHAP medios absolutos para todo el conjunto de bandas. Para estas pruebas se usaron los mismos conjuntos de datos de entrenamiento y validación. Según el factor de prueba, se descartaron las bandas que estuvieron fuera del conjunto de datos, de acuerdo con el factor SHAP evaluado.

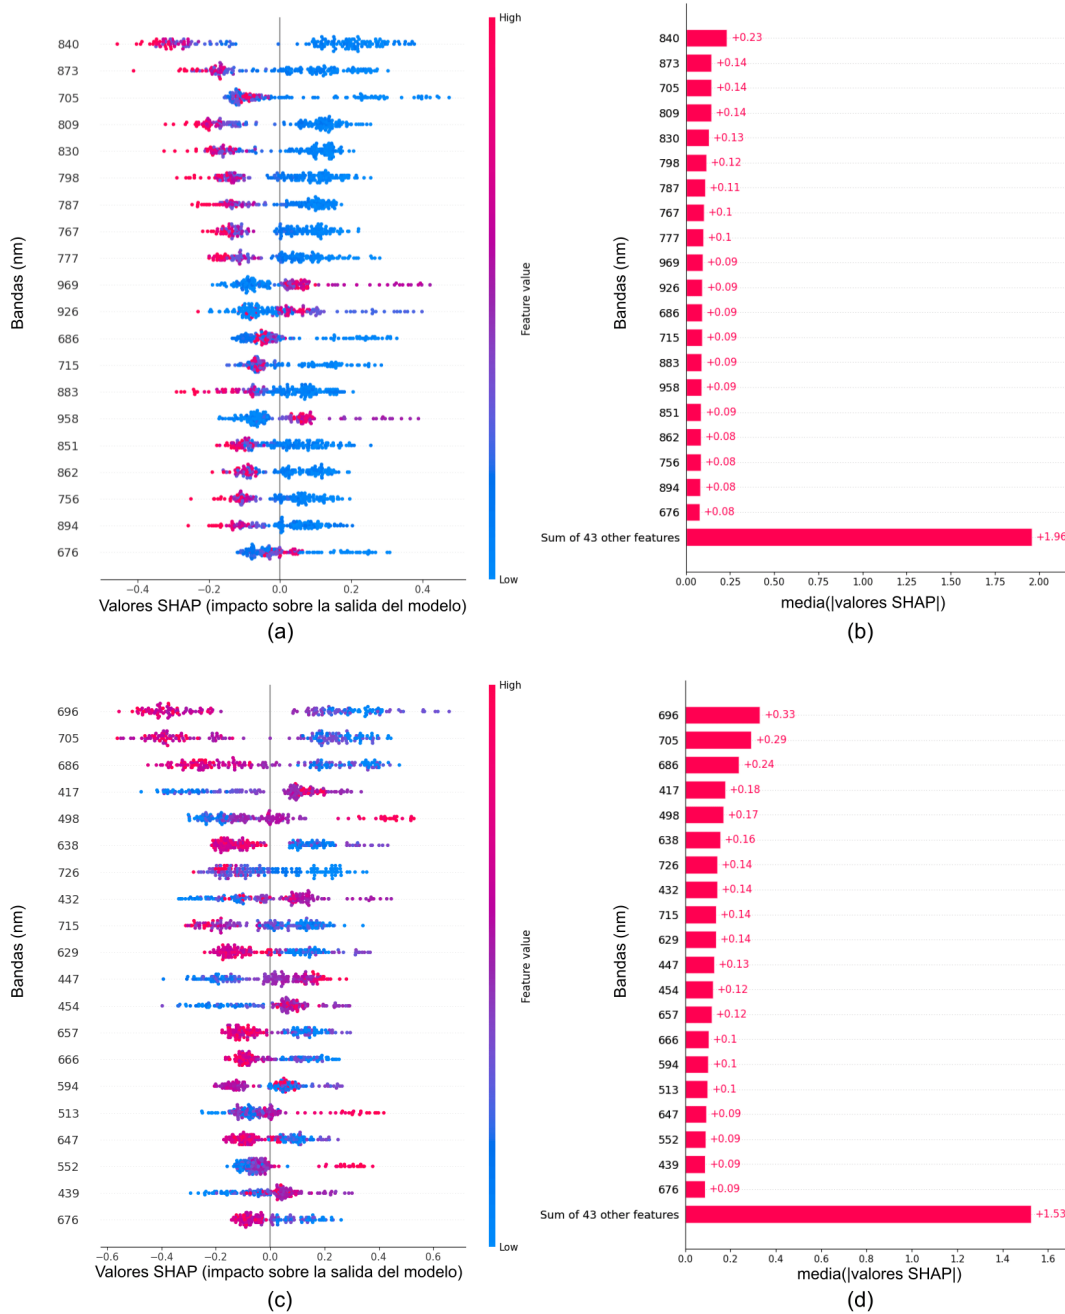


Figura 4.26: Gráficas SHAP de las bandas más incidentes en los modelos basados en bosques aleatorios (RF): (a, b) Conjunto de datos PRS-HSI. (c, d) Conjunto de datos HSI(PS).



**Tabla 4.9:** Exactitud de los modelos de acuerdo al Factor SHAP (0 ... 1) que permite obtener la suma de los valores SHAP medios absolutos ( $R^2$ , RMSE, MAE, BANDAS (Número de bandas requeridas)).

	FACTOR SHAP					
	1		0.9		0.8	
	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)
$R^2$	0.845	0.859	<b>0.846</b>	0.849	0.830	0.850
RMSE	1.170	1.148	<b>1.166</b>	1.188	1.228	1.186
MAE	0.910	0.830	<b>0.905</b>	0.830	0.940	0.850
BANDAS	63	63	<b>51</b>	40	40	31

	FACTOR SHAP					
	0.7		0.6		0.5	
	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)
$R^2$	0.817	<b>0.869</b>	0.773	0.857	0.739	0.850
RMSE	1.271	<b>1.109</b>	1.417	1.156	1.519	1.183
MAE	0.962	<b>0.814</b>	1.069	0.851	1.126	0.857
BANDAS	32	<b>24</b>	25	18	20	15

	FACTOR SHAP					
	0.4		0.3		0.2	
	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)	RF-PRS-HSI	RF-HSI(PS)
$R^2$	0.715	0.830	0.720	0.831	0.728	0.787
RMSE	1.587	1.260	1.573	1.257	1.552	1.412
MAE	1.209	0.946	1.191	0.949	1.147	1.030
BANDAS	15	10	11	8	7	5

Los resultados (Tabla. 4.9) reflejan que una disminución en el número de bandas generada por un factor SHAP menor a uno puede producir mejoras en los modelos. Por ejemplo, en el caso del modelo RF-HSI(PS), utilizando un factor SHAP de 0.7 se obtuvo un mejor modelo con un  $R^2$  de 0.869, un RMSE de 1.109 m y un MAE de 0.814 m, empleando solo las 24 bandas más incidentes. Para el modelo RF-PRS-HSI, se logró un mejor desempeño utilizando un factor SHAP de 0.9, lo que condujo a un  $R^2$  de 0.846, un RMSE de 1.166 m y un MAE de 0.905 m, con un total de 51 bandas, en comparación con las 63 bandas del modelo base RF-PRS-HSI.

Es destacable la diferencia entre el mejor modelo encontrado (RF-HSI(PS)), que no solo muestra el mejor rendimiento en cuanto a las métricas de evaluación, sino que también requiere un menor número de bandas espectrales (24) en comparación con las 51 requeridas por el mejor modelo RF-PRS-HSI. Además, al analizar el modelo con factores SHAP menores, se observa un deterioro notable del modelo solo para factores inferiores a 0.3. Hasta este punto, el  $R^2$  se mantuvo por encima de 0.83 empleando solo 8 bandas

espectrales para el modelo RF-HSI(PS), mientras que para el modelo RF-PRS-HSI, con factores SHAP menores a 0.7 (empleando 24 bandas), se observa una degradación notable de sus métricas. Esto demuestra cómo el modelo RF-HSI(PS) logra mejores resultados al emplear un menor número de bandas, y cómo el método SHAP permite no solo simplificar el conjunto de datos, sino también mejorar el desempeño de los modelos al descartar aquellos atributos menos incidentes que pueden generar una distorsión en el modelo.

La comparación entre los modelos de bosques aleatorios (RF) no optimizados y optimizados para los conjuntos de datos PRS-HSI y HSI(PS) se puede observar en las gráficas de dispersión de las Figuras 4.27a y 4.27c. Los resultados indican que en ambos casos, los modelos optimizados logran reducir el error de predicción. Al analizar la dispersión de los conjuntos de datos, se observa que, en promedio, en el conjunto RF-HSI(PS), el umbral de dispersión disminuyó (tomado como referencia a 1.96 SD (desviación estándar)) para una sobreestimación positiva de 2.25 m a 2.15 m y de 2.27 m a 2.21 m para la subestimación, al comparar las gráficas Bland-Altman del modelo base con las del modelo optimizado (Figuras 4.27b y 4.27d). Esto se refleja en los resultados de las métricas de evaluación de la Tabla 4.9. Sin embargo, aún persisten valores atípicos que aunque han reducido su error en comparación con el modelo no optimizado, no pueden mejorarse. Estos valores atípicos podrían explicarse por alguna reflexión atípica en el punto evaluado o un error en la profundidad de referencia establecida (carta náutica).

### **Ventajas de un modelo optimizado**

Son varias las ventajas que se destacan al usar un modelo de aprendizaje de máquina optimizado como modelo batimétrico que emplee menos atributos para generar una buena predicción. Entre las más relevantes se tienen:

- Reducción de complejidad: Al usar menos atributos, el modelo se simplifica, lo que facilita su interpretación y mantenimiento.

- Mejora en el desempeño: Los modelos optimizados pueden ser más eficientes y rápidos, lo que permite un procesamiento más ágil de grandes conjuntos de datos.
- Reducción en la distorsión y error de predicción: Al enfocarse solo en las bandas espectrales más incidentes, se minimiza el ruido y las variables irrelevantes que pueden afectar la precisión del modelo.
- Costo computacional reducido: Usar un menor número de bandas disminuye significativamente el tiempo y los recursos necesarios para generar una predicción sobre una captura hiperespectral completa.

Los beneficios computacionales para los datos hiperespectrales PRISMA son evidentes. Para una captura hiperespectral completa PRS-HSI ( $1222 \times 1195$ ) con 63 bandas, el procesamiento implica más de 90 millones de píxeles. En comparación, para el conjunto con resolución pancromática (HSI-PS), que es 36 veces mayor que el PRS-HSI pero con la misma cantidad de bandas, se requieren procesar más de 3300 millones de píxeles, implicando un tiempo de procesamiento de aproximadamente 10 minutos para el modelo RF-HSI(PS). Dado esto, al emplear el modelo RF-PRS-HSI-O51, se reduce la cantidad de píxeles a procesar de manera significativa al utilizar 12 bandas espectrales menos, lo que mejora la eficiencia computacional. Por otro lado, al utilizar el modelo RF-HSI(PS)-O24, el procesamiento es aún más eficiente, disminuyendo la cantidad de píxeles a procesar 2.625 veces en comparación con el modelo que usa las 63 bandas, lo que reduce el tiempo de procesamiento a aproximadamente 4 minutos por captura ( $7332 \times 7170 \times 24$ ).

La optimización de los modelos batimétricos no solo mejora la precisión y el desempeño del modelo, sino que también ofrece importantes ventajas en términos de eficiencia computacional. Esto es crítico cuando se trabaja con grandes volúmenes de datos, como en el caso de capturas hiperespectrales completas, permitiendo un procesamiento más rápido y eficiente, lo que es esencial para aplicaciones en tiempo real y análisis de grandes áreas geográficas.

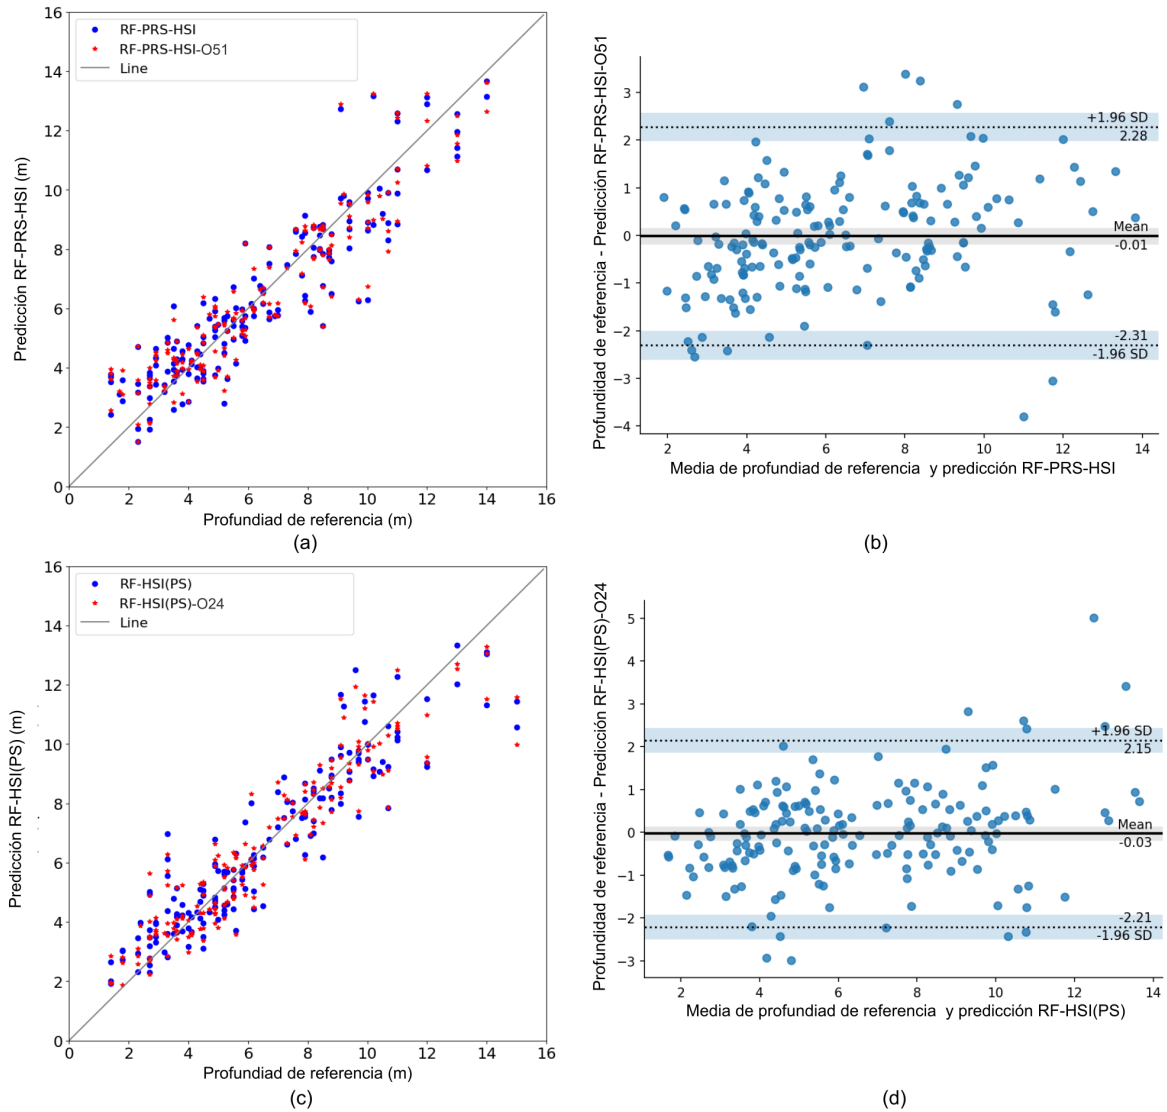


Figura 4.27: Comparación entre de los modelos basados en bosques aleatorios (RF-PRS-HSI y RF-HSI(PS)) sin optimizar (63 bandas) y (RF-PRS-HSI-O51 y RF-HSI(PS)-O24) optimizados (51 y 24 bandas respectivamente): (a, c) Profundidad estimada frente a profundidad de referencia. (b, d) Diagrama Bland-Altman.

### 4.2.9. Validación de los modelos

Al igual que en la sección 4.1.9 del estudio de batimetría hiperespectral aérea, se implementó el método de interpolación kriging (K) con todo el conjunto de entrenamiento de los valores de profundidad georreferenciados, el cual se usó como método estándar de comparación y validación de los modelos batimétricos.

Para validar el resultado de los modelos RF-PRS-HSI, RF-HSI(PS) y los modelos RF-PRS-HSI-O51 y RF-HSI(PS)-O24 optimizados que solo usan 51 y 24 bandas espectrales, además del método K. Se usaron los datos de los 57 puntos marcados en color amarillo sobre la carta náutica (Figura 4.20) que forman la transecta de validación. Los resultados de esta evaluación se muestran en la Tabla 4.10 y en la Figura 4.28.

**Tabla 4.10:** Precisión de los modelos basados en bosques aleatorios: modelos base (RF-PRS-HSI y RF-HSI(PS)), modelos optimizados (RF-PRS-HSI-O51 y RF-HSI(PS)-O24) e interpolación Kriging (K). En términos de  $R^2$ , RMSE y MAE sobre las transecta de validación (ver Figura 4.20).

Métrica	Predicción modelos				
	RF-PRS-HSI	RF-PRS-HSI-O51	RF-HSI(PS)	RF-HSI(PS)-O24	K
$R^2$	0.959	0.953	0.973	0.968	0.869
RMSE (m)	0.413	0.443	0.339	0.366	0.741
MAE (m)	0.178	0.216	0.173	0.137	0.619

Los resultados muestran que el modelo RF-HSI(PS) logra una predicción más consistente a lo largo de todo el perfil, presentando solo algunos sobre-picos con respecto a la batimetría de referencia, lo que condujo a un error absoluto promedio (MAE) de 0.173 m y a un RMSE de 0.339 m, con un alto coeficiente de determinación  $R^2$  de 0.973. Seguido del modelo RF-HSI(PS), el modelo optimizado basado en el conjunto de datos con resolución pancromática RF-HSI(PS)-O24 logró un alto  $R^2$  de 0.968, teniendo incluso un MAE menor de 0.137 m. Por otro lado, el método de interpolación kriging fue el que presentó el más bajo desempeño, con errores de 0.619 y 0.741 para MAE y RMSE, respectivamente. Estos resultados indican que los métodos de interpolación generan predicciones con mayor error cuando se extrapolan sus predicciones a zonas donde no hay puntos cercanos de referencia y donde sus predicciones se basan en la estadística de los puntos con los que fue




Figura 4.28: Validación de los modelos batimétricos basados en bosques aleatorios: modelos base (RF-PRS-HSI y RF-HSI(PS)), modelos optimizados (RF-PRS-HSI-O51 y RF-HSI(PS)-O24) y el método de interpolación kriging (K). Para la transecta de validación marcada en amarillo del área de estudio (ver Figura 4.20) .

generada la interpolación. En contraste, los modelos batimétricos RF, gracias a que usan la firma espectral del agua en el rango de profundidad para el cual se entrenaron, pueden extrapolar sus predicciones a cualquier zona que tenga las características espectrales del agua con las que fueron entrenados. En resumen, los modelos RF basados en imágenes hiperespectrales muestran una mayor precisión y capacidad para capturar las variaciones del fondo marino en comparación con el método de interpolación kriging, especialmente en áreas con datos batimétricos dispersos. Esto demuestra el potencial de la integración de datos hiperespectrales y modelos de aprendizaje de máquina para mejorar la precisión y resolución de los modelos batimétricos.

#### 4.2.10. Batimetría en resolución hiperespectral satelital y alta resolución pancromática del área de estudio

##### Predicción de una captura hiperespectral del área de estudio

El mejor modelo basado en bosques aleatorios (RF) encontrado para cada conjunto de datos PRS-HSI y HSI(PS) se usó para predecir una imagen completa del satélite PRISMA sobre la Bahía Samborombón, que representa un área de 900 km<sup>2</sup>. En esta predicción, se asignó una batimetría a cada píxel utilizando las bandas más influyentes para cada modelo, (51 para el modelo RF-PRS-HSI, 24 para RF-HSI(PS)). La Figura 4.21a muestra la captura hiperespectral usada para esta predicción. La predicción completa de ambos modelos para la captura hiperespectral se puede observar en la Figura 4.29Ia y IIa. Además, para estas mismas coordenadas de la captura hiperespectral se generó la interpolación kriging (K) basada en los puntos batimétricos de referencia para las dos resoluciones espaciales (1222 × 1195) para el conjunto PRS-HSI equivalente a 30 m por píxel y (7332 × 7170) para el conjunto HSI(PS) a 5 m por píxel. La Figura 4.29Ib y IIb muestra los resultados de la interpolación kriging.

En la Figura 4.29Ic y IIc se puede observar la diferencia entre los modelos RF-PRS-HSI-O51, RF-HSI(PS)-O24 y la interpolación K, dada la resta entre estos. Estas figuras resaltan las discrepancias entre los modelos de aprendizaje de máquina y uno de los métodos de interpolación de mayor precisión usados para generar mapas batimétricos. Las diferencias observadas indican cómo los modelos RF pueden capturar variaciones batimétricas que el método kriging puede suavizar o no representar con la misma precisión. Esto se evidencia en la mayor cantidad de detalles y variaciones capturadas por los modelos RF, destacando el modelo RF-HSI(PS) que, gracias a su mayor resolución espacial, puede captar variaciones del fondo a una resolución de 5 m por píxel. Esto es crítico para aplicaciones que requieren una representación precisa de la topografía subacuática y, según la Figura 4.29Ic y IIc, pueden tener diferencias de hasta  $\pm 2$  m de profundidad.




Figura 4.29: Predicción de los modelos batimétricos optimizados (RF) y el método de interpolación kriging (K) para la captura hiperespectral de la Figura 4.21a (área: 900 km<sup>2</sup>): I (resolución 30 m por píxel). I(a) RF-PRS-HSI-O51. I(b) K. I(c) Diferencia entre RF-PRS-HSI-O51 y K. II (resolución 5 m por píxel). II(a) RF-HSI(PS)-O24. II(b) K. II(c) Diferencia entre RF-HSI(PS)-O24 y K.



Al comparar el resultado de ambos modelos batimétricos (Figura 4.29Ia y IIa), puede verse que los resultados son muy similares. Sin embargo, en el modelo RF-HSI(PS)-O24 se puede apreciar un mayor nivel de detalle sobre la imagen. Esto se debe a la resolución espacial sobre la cual se genera la predicción, la cual le permite captar pequeñas variaciones del fondo. Aunque las figuras se muestran en el mismo tamaño, la resolución que representa el modelo RF-HSI(PS) por píxel es seis veces mayor que la del modelo RF-PRS-HSI. Por otro lado, la interpolación kriging (Figura 4.29Ib y IIb) presenta el mismo resultado sin importar que representan resoluciones espaciales diferentes. Esto muestra cómo el método kriging, ante una variación de escala espacial, simplemente genera una representación interpolada sin capturar las mismas variaciones detalladas que los modelos RF.

Finalmente, al comparar los resultados que muestran las diferencias entre los modelos batimétricos y el método kriging (Figura 4.29Ic y IIc), se puede ver que se marcan mayores diferencias para el modelo batimétrico RF-HSI(PS)-O24 (Figura 4.29IIc) en las zonas de menor profundidad. Esto indica que el modelo RF-HSI(PS)-O24 es capaz de capturar variaciones batimétricas más finas y detalladas, especialmente en áreas de menor profundidad, donde el método kriging tiende a suavizar las variaciones. Esta capacidad de los modelos RF para detectar detalles finos en la batimetría es crucial para aplicaciones que requieren una representación precisa de la topografía subacuática, destacando las diferencias de hasta  $\pm 2$  m de profundidad que pueden observarse en las comparaciones.

### **Mapa batimétrico del área de estudio**

Basado en la metodología aplicada a una captura hiperespectral, se extendió la predicción de los modelos batimétricos a todas las capturas hiperespectrales del área de estudio, excluyendo en estas las zonas costeras circundantes (ver Figura 4.21). Generando un mapa batimétrico a partir de cada modelo. En las Figuras 4.30 y 4.31 se observa el resultado del modelo RF-PRS-HSI-O51 a resolución hiperespectral satelital de 30 m por píxel, y del modelo RF-HSI(PS)-O24 a una resolución pancromática de 5 m por píxel.

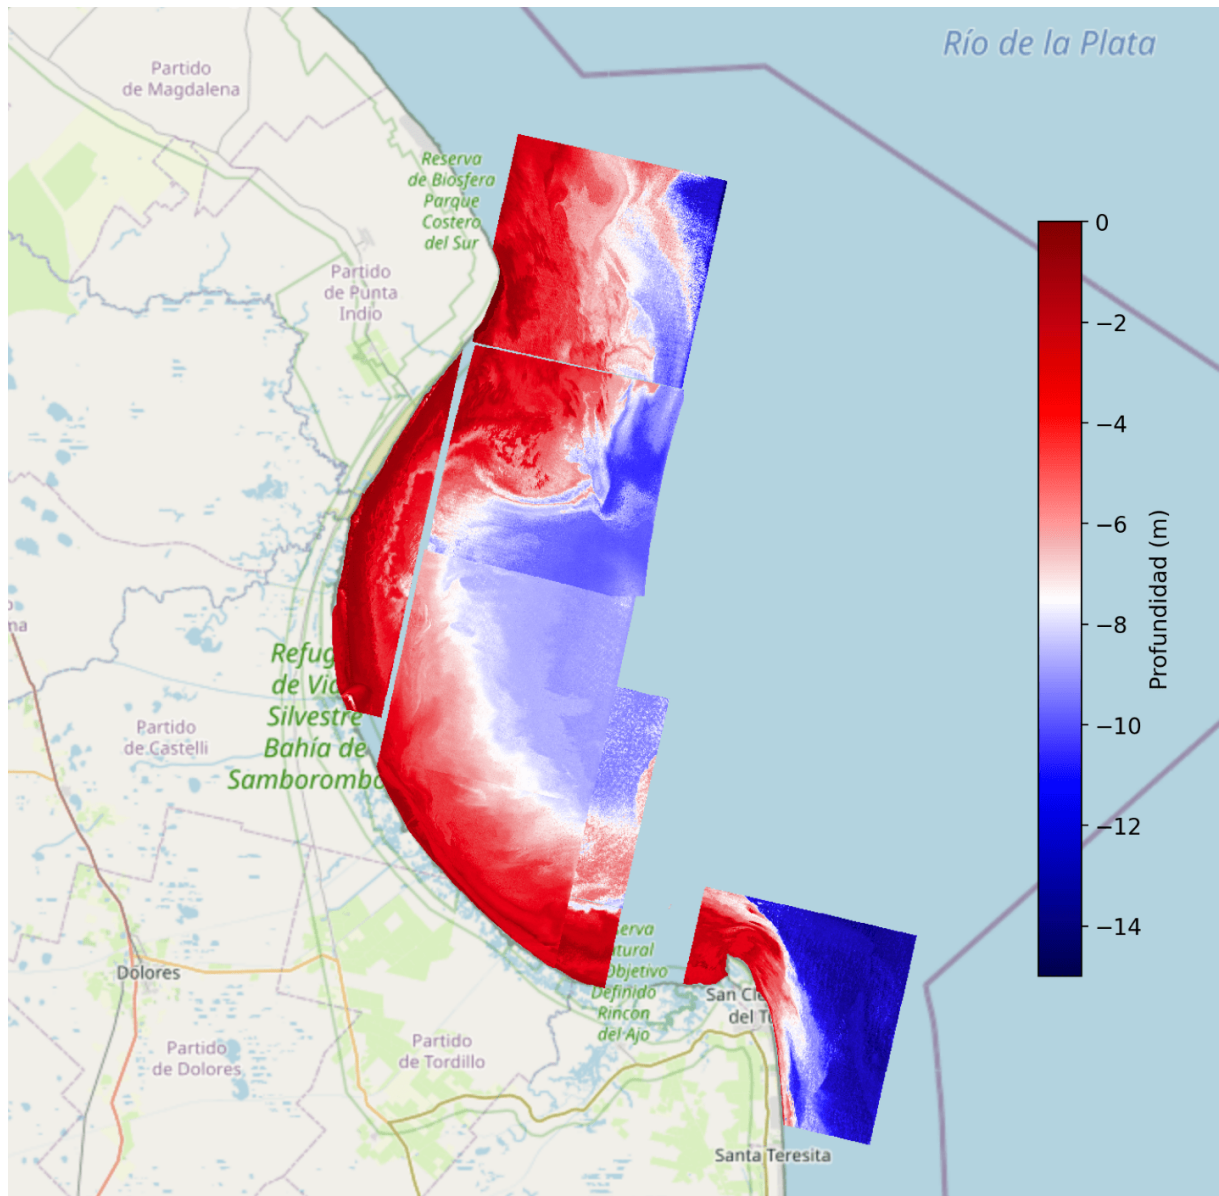


Figura 4.30: Mapa batimétrico del modelo RF-PRS-HSI-O51 (resolución 30 m por píxel) para todas las capturas hiperspectrales de la Figura 4.21 correspondientes al área de estudio (Bahía Samborombón) cubriendo una superficie de aproximadamente 4000 km<sup>2</sup>.

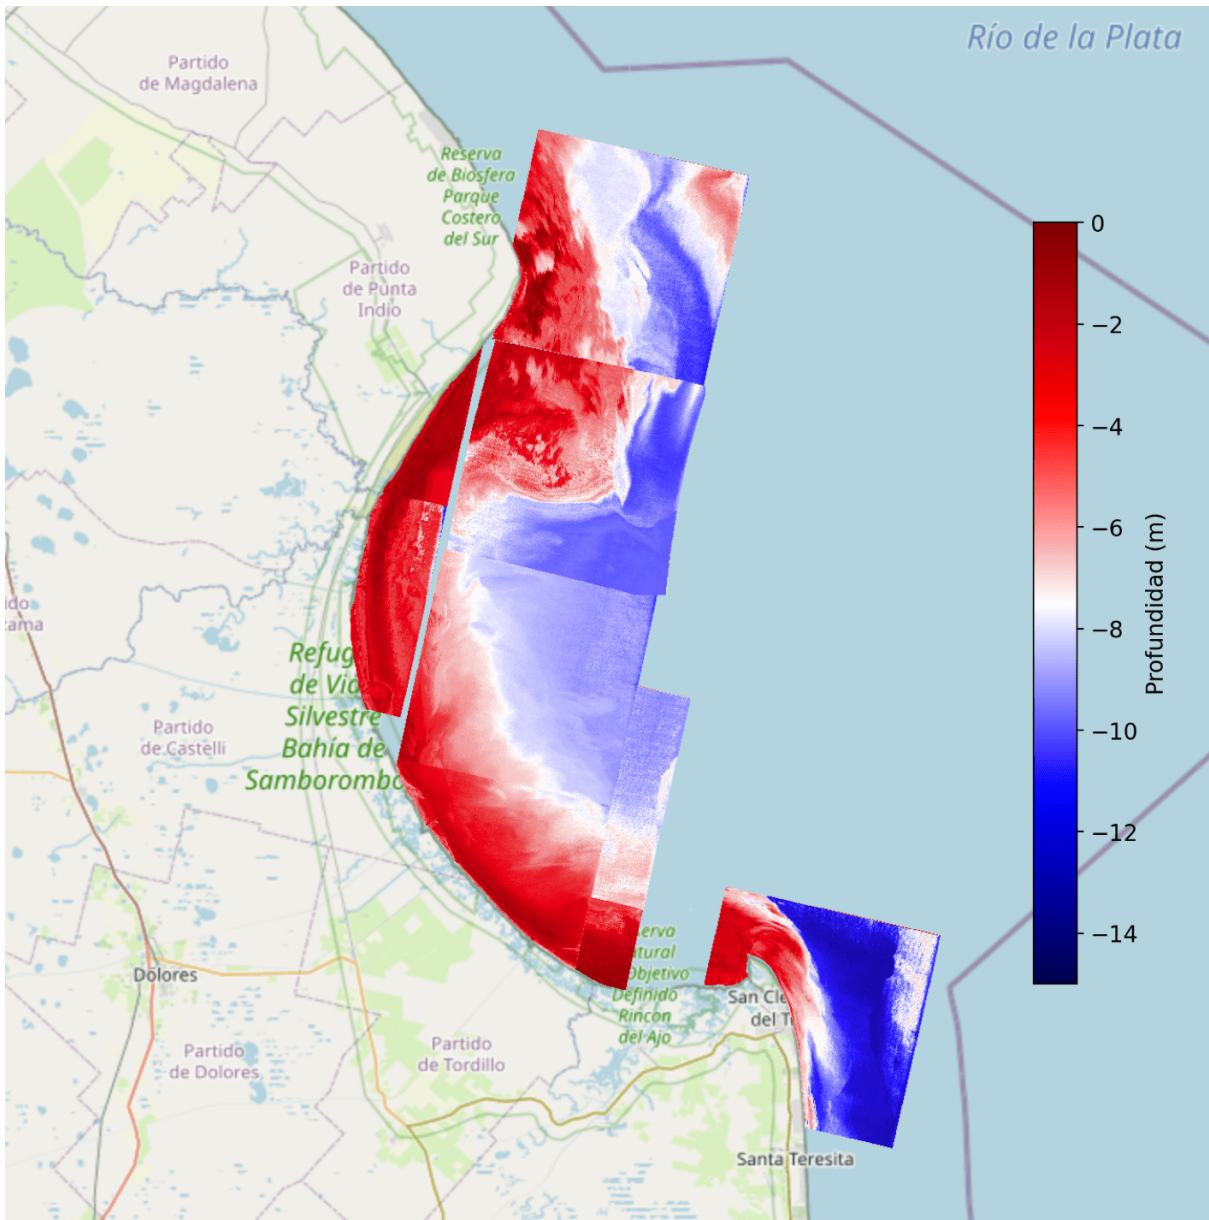


Figura 4.31: Mapa batimétrico del modelo RF-HSI(PS)-O24 (resolución 5 m por píxel) para todas las capturas hiperespectrales de la Figura 4.21 correspondientes al área de estudio (Bahía Samborombón) cubriendo una superficie de aproximadamente 4000 km<sup>2</sup>.

# Capítulo 5

## Conclusiones y trabajo futuro

### 5.1. Conclusiones

La monitorización y caracterización del agua presentan desafíos únicos en comparación con los entornos aéreos o terrestres, como infraestructura, protección, políticas científicas y recursos tecnológicos, financieros y humanos. Estas dificultades complican la gestión y conservación de los recursos hídricos.

En esta tesis, se desarrolló una plataforma de superficie no tripulada denominada EMAC-USV v2.0, basada en un concepto de código abierto y bajo costo, con un valor aproximado de 2300 USD, excluyendo el sensor comercial de concentración de carbono orgánico (CCO). Este costo es significativamente inferior al de las plataformas comerciales, igualando incluso el costo de un día de campaña de adquisición de datos con una embarcación tripulada, lo que hace de EMAC-USV v2.0 una herramienta accesible para la comunidad científica del agua, especialmente en países en vía de desarrollo. La plataforma opera en aguas poco profundas (menos de 50 metros) y destaca por su modularidad, permitiendo sustituir piezas en el campo y portar múltiples sensores para una caracterización detallada de los cuerpos de agua. Aunque su velocidad de crucero (1.5 m/s) es menor comparada con vehículos comerciales más costosos, su versatilidad, fácil transporte

y operación autónoma permiten reducir considerablemente los costos operativos y operar en superficies de poca profundidad y de difícil acceso. El vehículo en su modo autónomo opera sobre rutas de navegación programadas que proporcionan un registro homogéneo de los datos sobre el área de estudio, mejorando los resultados en el posprocesamiento de datos mediante métodos de interpolación o algoritmos de aprendizaje de maquina. Además de contar con la posibilidad operación manual vía RC si las condiciones de operación así lo requieren.

La batimetría es crucial en la caracterización de cuerpos de agua, permitiendo reconstruir la topografía subacuática del área de estudio. Desempeña un papel fundamental en la gestión y planificación costera, canales de navegación, diseño de obras y resolución de problemáticas como inundaciones, erosión costera y preservación de hábitats ecológicos. Generar batimetrías densas es un reto tecnológico que los enfoques basados solo en sensores y métodos de interpolación no pueden lograr con alta precisión, ya que requerirían un mapeo muy extenso y costoso. Sin embargo, enfoques recientes basados en imágenes han logrado resultados destacables en aguas claras, pero deficientes en aguas turbias.

Esta tesis desarrolló un enfoque innovador para obtener batimetrías densas y de alta resolución en áreas costeras con alta sedimentación, fusionando imágenes hiperespectrales con datos batimétricos mediante modelos de aprendizaje de maquina, dividida en dos estudios. En el primer estudio, se generó una batimetría densa en un área costera del estuario de Bahía Blanca de aproximadamente 800 m<sup>2</sup>, usando 100 puntos de muestra medidos con una ecosonda Garmin de 200 kHz a bordo del EMAC-USV (versión inicial) y una imagen hiperespectral aérea de 24 bandas. Los valores espectrales se usaron para entrenar modelos de bosques aleatorios (RF) y máquinas de soporte vectorial. El modelo RF mostró el mejor rendimiento, con un error cuadrático medio muy bajo (RMSE inferior a 20 cm) y un coeficiente de determinación ( $R^2$ ) significativamente alto, validando la precisión del modelo. Varias pruebas de ablación revelaron la importancia relativa de las longitudes de onda y la uniformidad en las predicciones bajo condiciones similares. Asi-

mismo, se validaron los modelos comparando los resultados con el método de interpolación kriging. Los resultados mostraron que kriging tiene mayor precisión en las transectas de referencia, pero el modelo batimétrico RF capta mejor las microvariaciones. El mejor modelo obtenido basado en bosques aleatorios permitió generar un mapa batimétrico denso a partir del conjunto de bandas hiperespectrales, con una resolución espacial de 3.6 cm por píxel del área de estudio. Aunque esta resolución espacial puede ser muy alta para algunos estudios, muestra el nivel de detalle al que se puede llegar con la metodología. La resolución espacial del píxel es inversamente proporcional a la altura de captura. Con lo cual, una captura a mayor altura permitiría mapear un área más grande sacrificando la marca de huella del píxel.

El segundo estudio mostró la replicabilidad de la metodología a mayores superficies y diferentes zonas de estudio con dinámicas complejas. Se extendió la metodología para generar batimetrías de alta resolución en un área extensa de la Bahía de Samborombón, provincia de Buenos Aires, de aproximadamente 4000 km<sup>2</sup>, usando capturas del satélite hiperespectral PRISMA (PRS-HSI), que fueron usadas como el conjunto hiperespectral de referencia. Se generó un conjunto de datos hiperespectrales adicional mediante la implementación de un método de fusión pancromática basado en análisis de componentes principales, que aprovecha la imagen pancromática disponible, para mejorar la resolución PRS-HSI de 30 m por píxel a 5 m por píxel (HSI(PS)). Además, se usaron 900 puntos batimétricos dispersos de una carta náutica del área de estudio. Con estos, se generaron dos conjuntos de datos que permitieron crear dos modelos batimétricos (RF-PRS-HSI y RF-HSI(PS)) a diferente resolución espacial. El mejor modelo encontrado se basó en el conjunto hiperespectral con resolución pancromática (RF-HSI(PS)), con un  $R^2$  de 0.859 y un error absoluto promedio bajo (MAE = 0.830 m). La optimización de los modelos, basada en las bandas más incidentes del modelo, permitió obtener modelos que utilizan un menor número de bandas: 51 para el modelo RF-PRS-HSI y 24 para RF-HSI(PS). Esto no solo reduce la distorsión y error de predicción al eliminar las bandas irrelevantes

que pueden afectar la precisión del modelo, sino que además implica un ahorro computacional de hasta 2.625 veces para una predicción completa de una captura hiperespectral con resolución pancromática ( $7333 \times 7170 \times 63$ ), que si se emplearan todas las bandas implicaría procesar más de 3300 millones de píxeles.

La validación de los modelos basada en una transecta de puntos no usada para el entrenamiento mostró que los modelos batimétricos RF presentaron un mejor rendimiento en todas las métricas respecto a kriging, obteniendo un RMSE de 0.339 m para el mejor modelo RF frente a 0.741 de kriging. Los resultados confirman que los métodos de interpolación generan predicciones con mayor error cuando se extrapolan a zonas sin puntos de referencia cercanos, basándose en la estadística de los puntos con los que se generó la interpolación. En contraste, los modelos batimétricos RF, al usar la firma espectral del agua en el rango de profundidad para el cual se entrenaron, pueden extrapolar sus predicciones a cualquier zona con características espectrales del agua similares a las del entrenamiento. Además, el modelo RF-HSI(PS) permite discriminar variaciones del fondo con mayor detalle gracias a su mayor resolución espacial adquirida a través del método de fusión pancromática, que inyecta esta riqueza espacial y espectral de la imagen pancromática de alta resolución a todo el conjunto hiperespectral. Los mejores modelos optimizados permitieron generar un mapa batimétrico con las nueve capturas disponibles sobre el área de estudio, cubriendo un área aproximada de  $4000 \text{ km}^2$  a dos resoluciones espaciales: 30 m por píxel para el conjunto PRS-HSI y 5 m por píxel para HSI(PS) con resolución pancromática.

En resumen, EMAC-USV v2.0 y la metodología de modelos batimétricos desarrollada en esta tesis ofrecen soluciones eficientes y económicas para el monitoreo y caracterización de cuerpos de agua, especialmente en áreas de difícil acceso, mejorando la precisión y reduciendo costos operativos y computacionales en la obtención de batimetrías de alta resolución a diferentes escalas y resoluciones espaciales.

## 5.2. Trabajo futuro

En cuanto a mejoras futuras en la plataforma EMAC-USV v2.0, se contempla la incorporación de una cámara de vídeo RGB. Lo cual permitirá la captación en tiempo real de la zona de operación circundante, brindando la capacidad de evitar obstáculos, especialmente en entornos complejos. Además, se planea integrar un muestreador de agua automático modular, aprovechando el volumen de almacenamiento adicional del casco, que representa aproximadamente el 40%. Esta mejora contribuirá a la eficiencia del monitoreo, ofreciendo una herramienta más completa y versátil para la investigación y la vigilancia en el ámbito acuático.

Además, se plantea el desafío de modificar la configuración electrónica del generador de imágenes hiperespectrales RIKOLA con el objetivo de extraer más de 24 bandas espectrales en la adquisición fuera de línea. Para abordar este reto, se quiere desarrollar un sistema embebido para emular el contexto operativo en línea de la cámara. Este sistema tiene la capacidad de permitir la extracción de hasta 394 bandas espectrales en el rango de 500 a 900 nm. La implementación exitosa de este enfoque proporcionaría información detallada para caracterizar con precisión los extremos espectrales del sedimento en suspensión. Esto, a su vez, permitiría calcular batimetrías densas en regiones más extensas donde no existe un patrón de referencia confiable, bajo la suposición de conocer la absorción y la microdispersión del sedimento. En áreas donde se tiene una aproximación de la profundidad del agua, la obtención de imágenes podría facilitar la determinación de la cantidad de sedimento en suspensión. Además, se abriría la posibilidad de detectar la presencia de sustancias químicas y contaminantes con propiedades de absorción espectral conocidas, abordando así una tarea esencial de monitoreo ambiental en diversas ubicaciones a lo largo del estuario de Bahía Blanca.

A pesar de que las imágenes satelitales hiperespectrales no pueden igualar la resolución espacial de una cámara aérea, sí permiten realizar análisis en áreas extensas, lo que facilita



abordar los mismos objetivos mencionados con la cámara hiperspectral aérea, pero a una escala geográfica mayor.

En términos de futuros estudios batimétricos, sería de gran interés aplicar esta metodología en otras zonas de estudio con características diferentes, como aguas cristalinas. Las hipótesis y estudios previos sugieren que esto podría resultar en modelos batimétricos con un menor margen de error en aguas someras, además de permitir la predicción de mayores profundidades. También sería valioso incorporar la plataforma EMAC-USV v2.0 para adquirir los datos batimétricos junto con parámetros de calidad del agua, lo que permitiría generar modelos que incluyan variables descriptivas de la profundidad adicionales, como la concentración de sedimentos en suspensión, entre otros parámetros que puedan considerarse relevantes.

# Apéndice A

## Contribuciones

Este trabajo de investigación ha realizado tres contribuciones significativas en el ámbito del monitoreo y caracterización de cuerpos de agua.

En primer lugar, se desarrolló un vehículo de superficie no tripulado de bajo costo y arquitectura abierta, que permite el registro y monitoreo de múltiples parámetros de calidad del agua y batimetría en diferentes entornos hídricos. En segundo lugar, se desarrolló una metodología innovadora que permite la creación de mapas batimétricos densos en aguas turbias mediante un modelo de aprendizaje automático que fusiona imágenes hiperespectrales aéreas y mediciones de ecosonda. Además, se extendió esta metodología de fusión de datos hiperespectrales con datos batimétricos para obtener mapas batimétricos de alta resolución en amplias zonas costeras, mediante modelos de aprendizaje de máquina optimizados que fusionan imágenes satelitales hiperespectrales y datos batimétricos, utilizando un menor número de bandas espectrales y alcanzando una resolución equivalente a la imagen pancromática de alta resolución del satélite.

## A.1. Artículos en revistas indexadas

- **Martinez Vargas, S.**, Vitale, A. J., Genchi, S. A., Nogueira, S. F., Arias, A. H., Perillo, G. M., Delrieux, C. A. (2023). *Monitoring Multiple Parameters in Complex Water Scenarios using a Low Cost Open Source Data Acquisition Platform*. HardwareX, e00492. [\[DOI\]](#)
- **Martinez Vargas, S.**, Delrieux, C. A., Blanco, K. L., y Vitale, A. (2021, December 1). *Dense Bathymetry in Turbid Coastal Zones Using Airborne Hyperspectral Images*. Photogrammetric Engineering & Remote Sensing, 87(12), 923–927. [\[DOI\]](#)
- Visconti, L. G., **Martinez Vargas, S.**, Rodríguez, M. S., Di Anibal, C. V., y Delrieux, C. (2023, March). *Determination of grated hard cheese adulteration by digital image analysis and multivariate analysis*. International Dairy Journal, 138, 105539. [\[DOI\]](#)

## A.2. Artículos en conferencias nacionales e internacionales

- **Martinez Vargas, S.**, Vitale, A. (2024). *Refinado pancromático: Una estrategia para incrementar la resolución en imágenes satelitales hiperespectrales*. LIII Jornadas Argentinas de Informática (JAIIO), Bahía Blanca, Argentina, 12-16 de agosto de 2024. ISSN 2451-7496. [\[URL\]](#)
- Vranic, Maria Laura., **Martinez Vargas, S.**, Cristos, Diego Sebastián., Pesquero, Natalia Victoria., Vorobioff, Juan., Delrieux, Claudio. (2024). *Análisis de imágenes hiperespectrales de maní contaminado con aflatoxinas*. XXX Congreso Argentino de ciencias de la computación (CACIC2024), La Plata, Argentina, 07-10 de octubre de 2024. [\[URL\]](#)

- **Martinez Vargas, S.**, Vitale, A., Genchi, S., Nogueira, S., Siben, A., Delrieux, C. y Perillo, G. (2023). *Vehículo autónomo de superficie de código abierto y bajo costo para la adquisición de parámetros de calidad del agua y batimetría*. XXX Jornadas de Jóvenes Investigadores, Asociación de Universidades del Grupo Montevideo, San Lorenzo, Paraguay, 11-12 de octubre de 2023. [[URL](#)]
- **Martinez Vargas, S.**, Delrieux, C. y Salomon, N. (2022). *Remote Sensing of anomalies in Wheat Crops using Aerial Hyperspectral Images*. Python Científico Latino América 2022, Salta, Argentina., 26-28 de septiembre de 2022. [[URL](#)]
- **Martinez Vargas, S.**, Delrieux, C., Vitale, A., y Blanco Monroy, K. L. (2021, November 3). *Regression Models for Dense Bathymetry in Turbid Coastal Areas*. 2021 XIX Workshop on Information Processing and Control (RPIC). [[DOI](#)]
- Massiris Fernández, M., Bajo, J., **Martinez Vargas, S.**, Fernández, J. Á., Delrieux, C. (2020). *Vision-Based Ergonomic Risk Estimation: Deep-learning Strategies*. 9th International Workshop on Soft Computing Applications, SOFA 2020, Arad, Romania, 27-29th November 2020. [[DOI](#)]

### A.3. Difusión en medios

- Crean vehículo acuático autónomo y barato para vigilar el estado del agua. (02 de Febrero de 2024). *PDM*. [[Noticia](#)]
- Aventura submarina: cómo los robots están revelando los secretos de ríos y lagos. (25 de Enero de 2024). *Alerta Digital*. [[Noticia](#)]
- Un barco suelto en Trenque Lauquen, La embarcación autónoma monitoreará el agua de ríos, mares y lagos. (22 de Enero de 2024). *Página12*. [[Noticia](#)]

- Relevaron con el nuevo VAS la planta de aguas residuales de Trenque Lauquen. (21 de Enero de 2024). *La Opinión Austral*. [[Noticia](#)]
- Lev, M. (21 de Enero de 2024). Diseñan una embarcación autónoma para analizar el agua en lagos, ríos y mares. *ArgenPorts*. [[Noticia](#)]
- Universidad Nacional del Sur: Investigadores crearon un vehículo de monitoreo ambiental autónomo y económico. (10 de Enero de 2024). *SudOeste BA*. [[Noticia](#)]
- En la UNS crearon un vehículo autónomo para conocer el estado del agua. (10 de Enero de 2024). *Diario Hoy*. [[Noticia](#)]
- Cucherenó, K. (08 de Enero de 2024) Investigadores crearon un vehículo de monitoreo ambiental autónomo y económico. *Argentina Investiga*. [[Noticia](#)]
- Costanzo, D. (23 de Diciembre de 2023) Bahía Blanca: crearon un catamarán que revoluciona el monitoreo del agua. *El Editor*. [[Noticia](#)]
- Premian a un estudiante de la UNS por desarrollar un vehículo de bajo costo que mide la calidad de los espejos de agua. (25 de Octubre de 2023). *Wips*. [[Noticia](#)]

#### A.4. Distinciones

- Distinción por mejor trabajo de investigación en el área de Ciencia, Tecnología e Innovación presentado en la *Trigésima Edición de las Jornadas de Jóvenes Investigadores de la Asociación de Universidades Grupo Montevideo (30° JJI AUGM 2023)* realizada en la Universidad Nacional de Asunción, República del Paraguay. (11 al 13 de octubre de 2023). Por el trabajo: *Vehículo autónomo de superficie de código abierto y bajo costo para la adquisición de parámetros de calidad del agua y batimetría*, en la modalidad Oral, con los autores: **Martinez Vargas, S.** [[JJI-UNA-2023](#)] [[Noticias-UNS](#)]

# Bibliografía

- Akhtman, Y., Golubeva, E., Tutubalina, O., and Zimin, M. (2017). Application of hyperspectral images and ground data for precision farming. *GEOGRAPHY, ENVIRONMENT, SUSTAINABILITY*, 10(4):117–128.
- Alfonso, M., Brendel, A., Vitale, A., Seitz, C., Piccolo, M., and Perillo, G. (2018). Drivers of ecosystem metabolism in two managed shallow lakes with different salinity and trophic conditions: The sauce grande and la salada lakes (argentina). *Water*, 10(9):1136.
- Allouis, T., Bailly, J.-S., Pastol, Y., and Roux, C. (2010). Comparison of lidar waveform processing methods for very shallow water bathymetry using raman, near-infrared and green signals. *Earth Surface Processes and Landforms*, 35:640 – 650.
- Anisfeld, S. C. (2011). *Water Resources*. Island Press.
- Bacino, G., Alonso, G., Billet, C., Dragani, W., Bedmar, J., and Farenga, M. (2023). Assessing the morphological evolution of a breakwater-protected sandy beach by means of uav surveys at mar del plata, argentina. *Journal of South American Earth Sciences*, 127:104379.
- Bacino, G. L., Dragani, W. C., and Codignotto, J. O. (2019). Changes in wave climate and its impact on the coastal erosion in samborombón bay, río de la plata estuary, argentina. *Estuarine Coastal and Shelf Science*, 219:71–80.

- Bahía Samborombón (Buenos Aires y APN) (2020). <https://www.argentina.gob.ar/ambiente/agua/humedales/sitiosramsar/>.
- Bangira, T., Alfieri, S. M., Menenti, M., and van Niekerk, A. (2019). Comparing thresholding with machine learning classifiers for mapping complex water. *Remote Sensing*, 11(11):1351.
- Bartram, J. and Ballance, R. (1996). *Water Quality Monitoring*. CRC Press.
- Belgiu, M. and Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114:24–31.
- Bernard, S., Heutte, L., and Adam, S. (2009). On the selection of decision trees in random forests. *2009 International Joint Conference on Neural Networks*.
- Bian, J., Zhang, Z., Chen, J., Chen, H., Cui, C., Li, X., Chen, S., and Fu, Q. (2019). Simplified evaluation of cotton water stress using high resolution unmanned aerial vehicle thermal imagery. *Remote Sensing*, 11(3):267.
- Boateng, E. Y., Otoo, J., and Abaye, D. A. (2020). Basic tenets of classification algorithms k-nearest-neighbor, support vector machine, random forest and neural network: A review. *Journal of Data Analysis and Information Processing*, 08(04):341–357.
- Bohnenkamp, D., Behmann, J., and Mahlein, A.-K. (2019). In-field detection of yellow rust in wheat on the ground canopy and uav scale. *Remote Sensing*, 11(21):2495.
- Borkowski, G. and Młynarczyk, A. (2019). Remote sensing using unmanned aerial vehicles for tourist-recreation lake evaluation and development. *Quaestiones Geographicae*, 38(1):5–14.

- Boumpoulis, V., Michalopoulou, M., and Depountis, N. (2023). Comparison between different spatial interpolation methods for the development of sediment distribution maps in coastal areas. *Earth Science Informatics*, 16(3):2069–2087.
- Boyd, C. E. (2018). Water quality in freshwater bodies. *Oxford Bibliographies Online Datasets*.
- Branchet, P., Arpin-Pont, L., Piram, A., Boissery, P., Wong-Wah-Chung, P., and Doumenq, P. (2021). Pharmaceuticals in the marine environment: What are the present challenges in their monitoring? *Science of The Total Environment*, 766:142644.
- Breiman, L. (2001). Random forests.
- Brook, A., De Micco, V., Battipaglia, G., Erbaggio, A., Ludeno, G., Catapano, I., and Bonfante, A. (2020). A smart multiple spatial and temporal resolution system to support precision agriculture from satellite images: Proof of concept on aglianico vineyard. *Remote Sensing of Environment*, 240:111679.
- Camino, C., González-Dugo, V., Hernández, P., Sillero, J., and Zarco-Tejada, P. J. (2018). Improved nitrogen retrievals with airborne-derived fluorescence and plant traits quantified from vnir-swir hyperspectral imagery in the context of precision agriculture. *International Journal of Applied Earth Observation and Geoinformation*, 70:105–117.
- Capolupo, A., Kooistra, L., Berendonk, C., Boccia, L., and Suomalainen, J. (2015). Estimating plant traits of grasslands from uav-acquired hyperspectral images: A comparison of statistical approaches. *ISPRS International Journal of Geo-Information*, 4(4):2792–2820.
- Carlson, D. F., Fürsterling, A., Vesterled, L., Skovby, M., Pedersen, S. S., Melvad, C., and Rysgaard, S. (2019). An affordable and portable autonomous surface vehicle with obstacle avoidance for coastal ocean monitoring. *HardwareX*, 5:e00059.



- Carrasco, O., Gomez, R. B., Chainani, A., and Roper, W. E. (2003). Hyperspectral imaging applied to medical diagnoses and food safety. *Geo-Spatial and Temporal Image and Data Exploitation III*.
- Carvalho, L., Mackay, E. B., Cardoso, A. C., Baattrup-Pedersen, A., Birk, S., Blackstock, K. L., Borics, G., Borja, A., Feld, C. K., Ferreira, M. T., Globevnik, L., Grizzetti, B., Hendry, S., Hering, D., Kelly, M., Langaas, S., Meissner, K., Panagopoulos, Y., Penning, E., Rouillard, J., Sabater, S., Schmedtje, U., Spears, B. M., Venohr, M., van de Bund, W., and Solheim, A. L. (2019). Protecting and restoring europe’s waters: An analysis of the future development needs of the water framework directive. *Science of The Total Environment*, 658:1228–1238.
- Chapman, D. V., Warner, S., and Dickens, C. (2021). Approaches to water monitoring. *Encyclopedia of the UN Sustainable Development Goals*, page 1–11.
- Chen, C. (2006). *Signal and Image Processing for Remote Sensing*. CRC Press.
- Chen, W., Hao, X., Yan, K., Lu, J., Liu, J., He, C., Zhou, F., and Xu, X. (2021). The mobile water quality monitoring system based on low-power wide area network and unmanned surface vehicle. *Wireless Communications and Mobile Computing*, 2021:1–16.
- Chidiac, S., El Najjar, P., Ouaini, N., El Rayess, Y., and El Azzi, D. (2023). A comprehensive review of water quality indices (wqis): history, models, attempts and perspectives. *Reviews in Environmental Science and Bio/Technology*, 22(2):349–395.
- Chuvieco, E. and Salinero, E. C. (1990). *Fundamentos de teledetección espacial*. Ediciones Rialp.
- Clark, R. N. and Swayze, G. A. (1995). Mapping minerals, amorphous materials, environmental materials, vegetation, water, ice and snow, and other materials: The usgs tricorder algorithm. In *semanticscholar.org*.

- Dekker, A. G., Brando, V. E., and Anstee, J. M. (2005). Retrospective seagrass change detection in a shallow coastal tidal Australian lake. *Remote Sensing of Environment*, 97(4):415–433.
- Eismann, M. T. (2012). *Hyperspectral Remote Sensing*. SPIE-International Society for Optical Engineering.
- Estaciones de Monitoreo Ambiental Costero (EMAC) (03 de Febrero de 2023). <http://emac.iado-conicet.gob.ar/>.
- Feng, Y.-Z. and Sun, D.-W. (2012). Application of hyperspectral imaging in food safety inspection and control: A review. *Critical Reviews in Food Science and Nutrition*, 52(11):1039–1058.
- Fenghua, Y., Tongyu, X., Wen, D., Hang, M., Guosheng, Z., and Chunling, C. (2017). Radiative transfer models (rtms) for field phenotyping inversion of rice based on UAV hyperspectral remote sensing. *International Journal of Agricultural and Biological Engineering*, 10(4):150–157.
- Francis, H. and Traykovski, P. (2021). Development of a highly portable unmanned surface vehicle for surf zone bathymetric surveying. *Journal of Coastal Research*, 37(5).
- Genchi, S. A., Vitale, A. J., Perillo, G. M. E., Seitz, C., and Delrieux, C. A. (2020). Mapping topobathymetry in a shallow tidal environment using low-cost technology. *Remote Sensing*, 12(9):1394.
- Gholizadeh, M., Melesse, A., and Reddi, L. (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors*, 16(8):1298.
- Gonzalez-Dugo, V., Hernandez, P., Solis, I., and Zarco-Tejada, P. (2015). Using high-resolution hyperspectral and thermal airborne imagery to assess physiological condition in the context of wheat phenotyping. *Remote Sensing*, 7(10):13586–13605.

- Govender, M., Chetty, K., and Bulcock, H. (2009). A review of hyperspectral remote sensing and its application in vegetation and water resource studies. *Water SA*, 33(2).
- Graves, J., Kuang, Y., and Zhu, M. (2021). Counterweight-pendulum energy harvester with reduced resonance frequency for unmanned surface vehicles. *Sensors and Actuators A: Physical*, 321:112577.
- Gregory, C. and Vardy, A. (2020). microusv: A low-cost platform for indoor marine swarm robotics research. *HardwareX*, 7:e00105.
- Hoge, J. and Leach, C. (2016). Epoxy resin infused boat hulls. *Reinforced Plastics*, 60(4):221–223.
- Hsu, C.-W., Chang, C.-C., and Lin, C.-J. (2003). A practical guide to support vector classification.
- Ibrahim, P. O., Sternberg, H., Samaila-Ija, H. A., Adgidzi, D., and Nwadiolor, I. J. (2022). Modelling topo-bathymetric surface using a triangulation irregular network (tin) of tunga dam in nigeria. *Applied Geomatics*, 15(1):281–293.
- Ilyas, T. F., Arkan, F., Kurniawan, R., Budianto, T. H., and Putra, G. B. (2021). Thingsboard-based prototype design for measuring depth and ph of kulong waters. *IOP Conference Series: Earth and Environmental Science*, 926(1):012025.
- Izzo, R. R., Lakso, A. N., Marcellus, E., Bauch, T., Raqueño, N., and van Aardt, J. (2019). An initial analysis of real-time suas-based detection of grapevine water status in the finger lakes wine country of upstate new york. *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IV*.
- Jamali, A., Castro, F. A., and Karaş, R. (2023). *Topological 3D Spatial Interpolation Based on the Interval-Valued Homotopy Continuation*. Springer, Cham.
- Jensen, J. R. (2007). *Remote Sensing of the Environment*. Pearson.

- Jin, X., Liu, S., Baret, F., Hemerlé, M., and Comar, A. (2017). Estimates of plant density of wheat crops at emergence from very low altitude uav imagery. *Remote Sensing of Environment*, 198:105–114.
- Jo, W., Hoashi, Y., Paredes Aguilar, L. L., Postigo-Malaga, M., Garcia-Bravo, J. M., and Min, B.-C. (2019). A low-cost and small usv platform for water quality monitoring. *HardwareX*, 6:e00076.
- Kakuta, S., Ariyasu, E., and Takeda, T. (2018). Shallow water bathymetry mapping using hyperspectral data. *International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 1539–1542.
- Khan, M. J., Khan, H. S., Yousaf, A., Khurshid, K., and Abbas, A. (2018). Modern trends in hyperspectral image analysis: A review. *IEEE Access*, 6:14118–14129.
- Kirk, J. T. O. (2010). *Light and photosynthesis in aquatic ecosystems*. Cambridge University Press.
- Kothari, V., Vij, S., Sharma, S., and Gupta, N. (2021). Correlation of various water quality parameters and water quality index of districts of uttarakhand. *Environmental and Sustainability Indicators*, 9:100093.
- Kremezi, M., Kristollari, V., Karathanassi, V., Topouzelis, K., Kolokoussis, P., Taggio, N., Aiello, A., Ceriola, G., Barbone, E., and Corradi, P. (2021). Pansharpening prisma data for marine plastic litter detection using plastic indexes. *IEEE Access*, 9:61955–61971.
- Kwon, S., Gwon, Y., Kim, D., Seo, I. W., and You, H. (2023). Unsupervised classification of riverbed types for bathymetry mapping in shallow rivers using uav-based hyperspectral imagery. *Remote Sensing*, 15(11):2803.

- Kwon, S., Shin, J., Seo, I. W., Noh, H., Jung, S. H., and You, H. (2022). Measurement of suspended sediment concentration in open channel flows based on hyperspectral imagery from uavs. *Advances in Water Resources*, 159:104076.
- Land, E. H. and McCann, J. J. (1971). Lightness and retinex theory. *Journal of the Optical Society of America*, 61(1):1.
- Landsat-8 (2023). <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>.
- Lee, Z., Carder, K. L., and Arnone, R. A. (2002). Deriving inherent optical properties from water color: a multiband quasi-analytical algorithm for optically deep waters. *Applied Optics*, 41(27):5755.
- Lee, Z., Carder, K. L., Mobley, C. D., Steward, R. G., and Patch, J. S. (1999). Hyperspectral remote sensing for shallow waters: 2 deriving bottom depths and water properties by optimization. *Applied Optics*, 38(18):3831.
- Liang, H. (2011). Advances in multispectral and hyperspectral imaging for archaeology and art conservation. *Applied Physics A*, 106(2):309–323.
- Loncan, L., de Almeida, L. B., Bioucas-Dias, J. M., Briottet, X., Chanussot, J., Dobigeon, N., Fabre, S., Liao, W., Licciardi, G. A., Simoes, M., Tournet, J.-Y., Veganzones, M. A., Vivone, G., Wei, Q., and Yokoya, N. (2015). Hyperspectral pansharpener: A review. *IEEE Geoscience and Remote Sensing Magazine*, 3(3):27–46.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, pages 91–110.
- Lu, B., Dao, P., Liu, J., He, Y., and Shang, J. (2020). Recent advances of hyperspectral imaging technology and applications in agriculture. *Remote Sensing*, 12(16):2659.

- Lu, Q., Si, W., Wei, L., Li, Z., Xia, Z., Ye, S., and Xia, Y. (2021). Retrieval of water quality from uav-borne hyperspectral imagery: A comparative study of machine learning algorithms. *Remote Sensing*, 13(19):3928.
- Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. In Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R., editors, *Advances in Neural Information Processing Systems 30*, pages 4765–4774. Curran Associates, Inc.
- Lyzenga, D. (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.
- Ma, S., Zhou, Y., Gowda, P. H., Dong, J., Zhang, G., Kakani, V. G., Wagle, P., Chen, L., Flynn, K. C., and Jiang, W. (2019). Application of the water-related spectral reflectance indices: A review. *Ecological Indicators*, 98:68–79.
- Madeo, D., Pozzebon, A., Mocenni, C., and Bertoni, D. (2020). A low-cost unmanned surface vehicle for pervasive water quality monitoring. *IEEE Transactions on Instrumentation and Measurement*, 69(4):1433–1444.
- Marcovecchio, J. and Ferrer, L. (2005). Distribution and geochemical partitioning of heavy metals in sediments of the bahía blanca estuary, argentina. *Journal of Coastal Research*, 21(4):826–834.
- Martinez Vargas, S., Delrieux, C., Blanco, K. L., and Vitale, A. (2021a). Dense bathymetry in turbid coastal zones using airborne hyperspectral images. *Photogrammetric Engineering & Remote Sensing*, 87(12):923–927.

- Martinez Vargas, S., Delrieux, C., Vitale, A., and Blanco Monroy, K. L. (2021b). Regression models for dense bathymetry in turbid coastal areas. In *2021 XIX Workshop on Information Processing and Control (RPIC)*, pages 1–6.
- Martinez Vargas, S. and Vitale, A. (2024). Refinado pancromático: Una estrategia para incrementar la resolución en imágenes satelitales hiperespectrales. In *LIII Jornadas Argentinas de Informática (JAIIO), Bahía Blanca, Argentina, 12-16 de agosto de 2024*.
- Martinez Vargas, S., Vitale, A., Genchi, S., Nogueira, S., Siben, A., Arias, A., Delrieux, C., and Perillo, G. . (2023a). Monitoring multiple parameters in complex water scenarios using a low-cost open-source data acquisition platform. *HardwareX*, 87(12):923–927.
- Martinez Vargas, S., Vitale, A., Genchi, S., Nogueira, S., Siben, A., Delrieux, C., and Perillo, G. (2023b). Vehículo autónomo de superficie de código abierto y bajo costo para la adquisición de parámetros de calidad del agua y batimetría. In *XXX Jornadas de Jóvenes Investigadores, Asociación de Universidades del Grupo Montevideo AUGM-UNA, San Lorenzo (Paraguay), 11-13 de Octubre de 2023*, page 423.
- Matsushita, B., Yang, W., Jaelani, L., Setiawan, F., and Fukushima, T. (2016). Monitoring water quality with remote sensing image data. *Remote Sensing for Sustainability*, pages 163,184.
- Matthews, M. W. (2011). A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. *International Journal of Remote Sensing*, 32(21):6855–6899.
- McElarney, Y. R. and Rippey, B. (2009). A comparison of lake classifications based on aquatic macrophytes and physical and chemical water body descriptors. *Hydrobiologia*, 625(1):195–206.
- Merrick, L. and Taly, A. (2020). The explanation game: Explaining machine learning models using shapley values. *Lecture Notes in Computer Science*, page 17–38.

- Mills, J. O., Jalil, A., and Stanga, P. E. (2017). Electronic retinal implants and artificial vision: journey and present. *Eye*, 31(10):1383–1398.
- Misra, A., Vojinovic, Z., Ramakrishnan, B., Luijendijk, A., and Ranasinghe, R. (2018). Shallow water bathymetry mapping using support vector machine (svm) technique and multispectral imagery. *International Journal of Remote Sensing*, 39:4431–4450.
- Mission Planner Software (03 de Agosto de 2023). <https://ardupilot.org/planner/>.
- Mobley, C. D. (1994). *Light and Water*. Academic Press.
- MODIS (2024). <https://modis.gsfc.nasa.gov/>.
- Molday, R. S. and Moritz, O. L. (2015). Photoreceptors at a glance. *Journal of Cell Science*, 128(22):4039–4045.
- Odetti, A., Bruzzone, G., Altosole, M., Viviani, M., and Caccia, M. (2020). Swamp, an autonomous surface vehicle expressly designed for extremely shallow waters. *Ocean Engineering*, 216:108205.
- Pan, Z., Glennie, C., Fernandez-Diaz, J. C., and Starek, M. (2016). Comparison of bathymetry and seagrass mapping with hyperspectral imagery and airborne bathymetric lidar in a shallow estuarine environment. *International Journal of Remote Sensing*, 37:516–536.
- Papadopoulou, M., Lafazani, P., E.R., M., M., T.-S., and Doxani, G. (2015). Creation of digital bathymetric maps using high resolution satellite imagery and multispectral bathymetric modeling for shallow waters. *Measuring and Mapping the Earth, Special issue for Professor Emeritus Christogeorgis Kaltsikis. School of Rural and Surveying Engineers, Aristotle University Thessalonica*.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau,



- D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Piccolo, M., Perillo, G., and Melo, W. (2008). The bahía blanca estuary: an integrated overview of its geomorphology and dynamics. *Perspectives on integrated coastal zone management in South America*, pages 219–229.
- Popovich, Cecilia A. Marcovecchio, J. E. (2008). Spatial and temporal variability of phytoplankton and environmental factors in a temperate estuary of south america (atlantic coast, argentina). *Continental Shelf Research*, 28:236–244.
- Potokar, E., Lay, K., Norman, K., Benham, D., Neilsen, T. B., Kaess, M., and Mangelson, J. G. (2022). Holocean: Realistic sonar simulation. *2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*.
- PRISMA (2019). <https://www.asi.it/en/earth-science/prisma/>.
- Revollo, N. V., Revollo, G. N., Cisneros, M. A. H., Delrieux, C. A., and Piccolo, M. C. (2019). Assessing the evolution in remotely sensed vegetation index using image processing techniques. *Anuário do Instituto de Geociências - UFRJ*, 42:27–41.
- Rigatti, S. J. (2017). Random forest. *Journal of Insurance Medicine*, 47(1):31–39.
- Rikola (2015). *Rikola Hyperspectral Imager - Quick start Guide*. Kaitoväylä, Oulu, Finland. Rikola Ltd.
- Rybin, V. G., Kolev, G. Y., Karimov, T. I., Ostrovskii, V. Y., Druzhina, O. S., and Sigaeva, M. S. (2020). Estimating the autonomy range of the battery-powered small unmanned surface vehicle. *2020 Ural Smart Energy Conference (USEC)*.
- Saalidong, B. M., Aram, S. A., Otu, S., and Lartey, P. O. (2022). Examining the dynamics of the relationship between water ph and other water quality parameters in ground and surface water systems. *PLOS ONE*, 17(1):e0262117.

- Sahoo, R. N., Ray, S. S., and Manjunath, K. R. (2015). Hyperspectral remote sensing of agriculture. *Current Science*, 108(5):848–859.
- Sarp, G. (2014). Spectral and spatial quality analysis of pan-sharpening algorithms: A case study in istanbul. *European Journal of Remote Sensing*, 47(1):19–28.
- Scherrer, B., Sheppard, J., Jha, P., and Shaw, J. A. (2019). Hyperspectral imaging and neural networks to classify herbicide-resistant weeds. *Journal of Applied Remote Sensing*, 13(04):1.
- Schölkopf, B. and Smola, A. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Adaptive Computation and Machine Learning. MIT Press, Cambridge, MA, USA. Parts of this book, including an introduction to kernel methods, can be downloaded <http://www.learning-with-kernels.org/sections/>.
- Scholz, M. and Yang, Q. (2010). Guidance on variables characterising water bodies including sustainable flood retention basins. *Landscape and Urban Planning*, 98(3–4):190–199.
- Schonlau, M. and Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal: Promoting communications on statistics and Stata*, 20(1):3–29.
- Seitz, C., Scordo, F., Vitale, A. J., Vélez, M. I., and Perillo, G. M. (2020). The effects of extreme drought events on the morphometry of shallow lakes: Implications for sediment resuspension and littoral and pelagic zone distribution. *Journal of South American Earth Sciences*, 103:102743.
- Sentinel-3 (2023). <https://sentinels.copernicus.eu/web/sentinel/copernicus/sentinel-3>.

- Shao, G., Ma, Y., Malekian, R., Yan, X., and Li, Z. (2019). A novel cooperative platform design for coupled usv–uav systems. *IEEE Transactions on Industrial Informatics*, 15(9):4913–4922.
- Siregar, S., Febriansyah, R., Sani, M. I., and Ikbal, U. (2020). Implementation of depth control using a blue robotic ping sonar altimeter and echo sounder in explorer class rov. *2020 International Conference on Electrical Engineering and Informatics (ICELTICs)*.
- Smyth, R. L., Fatima, U., Segarra, M., Borre, L., Zilio, M. I., Reid, B., Pincetl, S., Astorga, A., Huamantincó Cisneros, M. A., Conde, D., Harmon, T., Hoyos, N., Escobar, J., Lozoya, J. P., Perillo, G. M., Piccolo, M. C., Rusak, J. A., and Velez, M. I. (2021). Engaging stakeholders across a socio-environmentally diverse network of water research sites in north and south america. *Environmental Development*, 38:100582.
- Sousa, J. B. and Andrade Gonçalves, G. (2010). Unmanned vehicles for environmental data collection. *Clean Technologies and Environmental Policy*, 13(2):369–380.
- Strobl, R. O. and Robillard, P. D. (2008). Network design for water quality monitoring of surface freshwaters: A review. *Journal of Environmental Management*, 87(4):639–648.
- Stumpf, R., Holderied, K., and Sinclair, M. (2003). Determination of water depth with high-resolution satellite imagery over variable bottom types. *Limnol. Oceanogr*, 48:547–556.
- Su, H., Liu, H., and Heyman, W. (2008). Automated derivation of bathymetric information from multi-spectral satellite imagery using a non-linear inversion model. *Marine Geodesy*, 31:281–298.
- Summers, K. (2020). *Water Quality: Science, Assessments and Policy*. IntechOpen.
- Swathika, R. and Sharmila, T. S. (2018). Image fusion for modis and landsat images using top hat based moving technique with fis. *Cluster Computing*, 22(S5):12939–12947.

- Sylvester, E. V. A., Bentzen, P., Bradbury, I. R., Clément, M., Pearce, J., Horne, J., and Beiko, R. G. (2017). Applications of random forest feature selection for fine-scale genetic population assignment. *Evolutionary Applications*, 11(2):153–165.
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer-Verlag, Berlin, Heidelberg, 1st edition.
- Thomas, C., Ranchin, T., Wald, L., and Chanussot, J. (2008). Synthesis of multispectral images to high spatial resolution: A critical review of fusion methods based on remote sensing physics. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5):1301–1312.
- Touzout, W., Benmoussa, Y., Benazzouz, D., Moreac, E., and Diguët, J.-P. (2021). Unmanned surface vehicle energy consumption modelling under various realistic disturbances integrated into simulation environment. *Ocean Engineering*, 222:108560.
- Tu, T.-M., Huang, P., Hung, C.-L., and Chang, C.-P. (2004). A fast intensity–hue–saturation fusion technique with spectral adjustment for ikonos imagery. *IEEE Geoscience and Remote Sensing Letters*, 1(4):309–312.
- Tyralis, H., Papacharalampous, G., and Langousis, A. (2019). A brief review of random forests for water scientists and practitioners and their recent history in water resources.
- Usali, N. and Ismail, M. H. (2010). Use of remote sensing and gis in monitoring water quality. *Journal of Sustainable Development*, 3(3).
- Uudeberg, K., Ansko, I., Põru, G., Ansper, A., and Reinart, A. (2019). Using optical water types to monitor changes in optically complex inland and coastal waters. *Remote Sensing*, 11(19):2297.

- van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., and Yu, T. (2014). scikit-image: image processing in python. *PeerJ*, 2:e453.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer, New York, NY, USA.
- Villa, J. L., Paez, J., Quintero, C., Yime, E., and Cabrera, J. (2016). Design and control of an unmanned surface vehicle for environmental monitoring applications. *2016 IEEE Colombian Conference on Robotics and Automation (CCRA)*.
- Vitale, A. J., Perillo, G. M., Genchi, S. A., Arias, A. H., and Piccolo, M. C. (2018). Low-cost monitoring buoys network tracking biogeochemical changes in lakes and marine environments – a regional case study. *Pure and Applied Chemistry*, 90(10):1631–1646.
- Vivone, G., Alparone, L., Chanussot, J., Dalla Mura, M., Garzelli, A., Licciardi, G. A., Restaino, R., and Wald, L. (2015). A critical comparison among pansharpening algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5):2565–2586.
- Wang, L., Pu, H., and Sun, D.-W. (2016). Estimation of chlorophyll-a concentration of different seasons in outdoor ponds using hyperspectral imaging. *Talanta*, 147:422–429.
- Wang, Y., Zhou, X., Li, C., Chen, Y., and Yang, L. (2020). Bathymetry model based on spectral and spatial multi-features of remote sensing image. *IEEE Geoscience and Remote Sensing Letters*, 17:37–41.
- Wang, Y.-G., Wu, J., Hu, Z.-H., and McLachlan, G. J. (2023). A new algorithm for support vector regression with automatic selection of hyperparameters. *Pattern Recognition*, 133:108989.

- Xiao, T., Segoni, S., Liang, X., Yin, K., and Casagli, N. (2023). Generating soil thickness maps by means of geomorphological-empirical approach and random forest algorithm in wanzhou county, three gorges reservoir. *Geoscience Frontiers*, 14(2):101514.
- Yanes Luis, S., Peralta, F., Tapia Cordoba, A., Rodriguez del Nozal, A., Toral Marin, S., and Gutierrez Reina, D. (2022). An evolutionary multi-objective path planning of a fleet of asvs for patrolling water resources. *Engineering Applications of Artificial Intelligence*, 112:104852.
- Yao, H., Li, X., Pang, H., Sheng, L., and Wang, W. (2020). Application of random forest algorithm in hail forecasting over shandong peninsula. *Atmospheric Research*, 244:105093.
- Zarco-Tejada, P., González-Dugo, V., and Berni, J. (2012). Fluorescence, temperature and narrow-band indices acquired from a uav platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117:322–337.
- Zeng, C., Richardson, M., and King, D. J. (2017). The impacts of environmental variables on water reflectance measured using a lightweight unmanned aerial vehicle (uav)-based spectrometer system. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130:217–230.
- Zolich, A., Palma, D., Kansanen, K., Fjørtoft, K., Sousa, J., Johansson, K. H., Jiang, Y., Dong, H., and Johansen, T. A. (2018). Survey on communication and networks for autonomous marine systems. *Journal of Intelligent & Robotic Systems*, 95(3–4):789–813.