



**UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE CIENCIAS**

Licenciatura en Geografía

Orientación: Técnicas aplicadas al análisis territorial

***Detección de la variabilidad espacial del frente
de turbidez principal del Río de la Plata
aplicando modelación basada en estadística
Bayesiana***

Andrea Barbieri Delgado

Tutor: Dr. Rodolfo Vögler, Centro Universitario Regional del Este, UDELAR

Tribunal: Dra. Virginia Fernández, Dr. Rodolfo Vögler, Dra. Martina Camiolo

Agradecimientos

En primer lugar, agradezco a Rodolfo Vögler por su orientación, guía y apoyo durante este proceso. Por toda la paciencia y confianza brindada. Por enseñarme a ser mejor profesional y persona. Gracias por contagiarme con tu optimismo y compartir en cada charla el entusiasmo y amor por la ciencia.

A Martina Camiolo por aceptar ser parte del tribunal.

A Virginia Fernández por aceptar ser parte del tribunal, por el apoyo, el incentivo y las oportunidades de crecimiento personal y profesional.

A Juan Bianchi del Instituto Nacional del Agua, quien de manera desinteresada proporcionó los datos de caudal del Río de la Plata.

A Pilar Díez, por su amistad incondicional, por el apoyo durante toda la carrera y por los momentos compartidos dentro y fuera del ámbito académico. Por los consejos y aliento constante.

A mis compañeros de carrera especialmente a Gonzalo por todas las horas compartidas y las anécdotas que nos quedaron y a Sebastián por la lectura, los consejos y la escucha constante. A mis compañeras y amigas de intercambio, Lore y Viki por su amistad y aprendizajes compartidos.

A Gabi por las horas de estudio compartidas, los viajes a Pando a las 6 am para ir a trabajar, las charlas y el apoyo incondicional.

A mi grupo de amigas, Mari, Carli, Nati y Belu por escucharme una y otra vez. Por el su apoyo incondicional y siempre creer en mí. A Juli por su amor incondicional.

A mis compañeras y compañeros de la División de Información Ambiental y del Departamento de Geografía por su constante aliento y consejos. De quienes he aprendido durante estos años compartidos, un poco de cada uno está volcado en esta tesis.

Al grupo dinamitas por mostrarme otra perspectiva del asunto, por escucharme y alentarme siempre.

Finalmente, a mi familia por su apoyo incondicional a pesar de sus dudas a la hora de seguir una carrera no tradicional. Especialmente agradezco a las mujeres de mi familia que con su sacrificio me regalaron el privilegio de poder seguir mi vocación.

Esta tesis va dedicada a mi prima Jessica quién siempre seguirá presente.

Tabla de contenido

Resumen

1.	8
2. Antecedentes	12
2.1 Características generales de los estuarios	12
2.2 Estuario del Río de la Plata	12
2.3 Frente de turbidez del Río de la Plata	14
2.4. Eventos El Niño/La Niña y caudal del Río de la Plata	16
2.5 Estadística Bayesiana	17
2.6 Teledetección	19
3. Justificación	22
4. Preguntas de investigación	23
5. Hipótesis.	24
6. Objetivos	24
6.1 Objetivo general.	24
6.2 Objetivos específicos	24
7. Materiales y Métodos	25
7.1 Área de estudio	25
7.2 Base de datos	26
7.3 Análisis de datos	29
7.3.1 Elección de escala temporal	29

7.3.2 Procesamiento de imágenes satelitales	33
7.3.4 Exploración de datos	35
7.4 Modelización espacio-temporal	36
7.4.1. Modelos jerárquicos y aproximación R-INLA	36
7.4.1 <i>Procesamiento R-INLA</i>	38
7.5 Evaluación de modelos	42
7.5.1 Criterio de Información de Desviación	42
7.5.2 Salida gráfica de los modelos	42
8. Resultados	44
8.1 Análisis de datos	44
8.1.1 Exploración de datos	44
8.2 Modelización: efecto de la variabilidad interanual con forzantes ambientales.	46
8.2.2. Escala temporal: 4 meses	59
8.2.3. Escala temporal: 6 meses	71
8.2.4. Comparación entre salidas de los modelos e imágenes satelitales	81
11. Bibliografía	91
12. Anexo:	99

RESUMEN

El Río de la Plata es el receptor de la segunda cuenca hídrica más grande de América del Sur. La confluencia de la descarga del Río de la Plata con las corrientes oceánicas de Brasil y Malvinas genera un frente de turbidez ([Piedra Cueva & Fossati, 2003](#)). Su posición y dinámica puede ser detectada a partir de imágenes satelitales. Esta tesis tuvo como objetivo implementar una metodología para detección del frente de turbidez del Río de la Plata a partir de imágenes satelitales obtenidas en el período 2011–2016 y la representación de cambios espaciales del frente principal en periodos interanuales de variabilidad extrema asociados a eventos El Niño/La Niña. Fue utilizada la modelización espacial basada en aproximaciones anidadas integradas de Laplace (INLA), aplicando un algoritmo determinístico integrado en la plataforma computacional R. Las variables explicativas integradas a los modelos fueron marea, caudal y viento (dirección y velocidad), mientras que la variable respuesta fue la reflectancia de luz generada en la superficie del agua a partir del contraste de color aportado por los sedimentos en suspensión. La combinación de la estadística Bayesiana y la teledetección permitió analizar la variabilidad espacial del frente de turbidez del Río de la Plata de manera integral, observándose que los eventos El Niño y La Niña tienen un efecto directo en la variabilidad espacio-temporal del frente de turbidez principal, afectando su posición y dinámica. El impacto del evento El Niño en la zona del Río de la Plata promueve un desplazamiento longitudinal del frente de turbidez en sentido costa-océano posicionándose hacia la zona externa del estuario, se observa mayor separación entre el frente principal y el secundario, siendo el caudal la variable que explica la mayor varianza de los datos y obtiene el mayor rendimiento en los modelos. En cambio, durante La Niña, el frente de turbidez experimenta una

retracción longitudinal en el sentido océano-costa y se posiciona en la zona media del estuario, la separación entre el frente principal y el secundario disminuye y es la dirección del viento la variable explicativa con mayor rendimiento en los modelos.

Palabras clave: Río de la Plata, turbidez, teledetección, estadística Bayesiana, R-INLA, eventos interanuales extremos

1. Introducción general

El estuario es un sistema compuesto por dos capas, una superior de agua dulce y otra inferior de agua salada; el espesor de la capa de agua dulce es prácticamente uniforme en todo el estuario mientras que la capa de agua salada disminuye a medida que avanza río arriba generando una cuña salina. El extremo de la cuña salina río arriba se define como frente salino. En sentido contrario, donde se produce el máximo avance del agua dulce hacia el océano se denomina frente de turbidez debido al contraste de color que se genera, resultado de las diferentes características físico-químicas de las dos masas de agua. En la columna vertical las dos masas de agua se diferencian por el cambio abrupto de concentración de salinidad, este límite es denominado haloclina ([Acha & Mianzan, 2003](#)). Los estuarios presentan una dinámica propia producto de las variables físicas, químicas, biológicas y geológicas que allí confluyen. Los movimientos de masas de agua dentro de un estuario dependen del caudal del río, de las oscilaciones de marea y de ciertas condiciones atmosféricas, especialmente dirección y velocidad del viento ([Piedra Cueva et al., 2003](#)).

En los estuarios, los cambios de las propiedades del agua tales como salinidad, temperatura y/o turbidez, ocurren de forma abrupta en el plano horizontal. Como resultado se conforman estrechas regiones denominadas frentes ([Simionato et al., 2011](#)). Los frentes estuarinos están controlados por el caudal del río, la marea y el viento ([Acha et al., 2015](#)). Desde el punto de vista físico existen tres tipos principales de frentes estuarinos: frentes de pluma e intrusión de marea; frentes de mezcla de mareas, y frentes de corte. Los frentes de pluma son aquellos que aparecen cuando ocurre alta descarga del río y reflujos de la marea, formándose una capa delgada de

agua dulce que fluye sobre el agua del océano. Los frentes de pluma están delimitados por un marcado cambio de turbidez (color) del agua o por una línea de espuma u otros detritos. Los frentes de intrusión están estrechamente relacionados con los frentes de pluma ya que estos se generan cuando el agua oceánica más densa ingresa por debajo hacia el continente y promueve un hundimiento lo cual produce una corriente de gravedad ([O'Donnell, 1993](#)). Los frentes de mezcla de mareas suceden entre las mareas mixtas y las aguas poco profundas de los bordes del estuario, mientras el agua más profunda del centro se encuentra influenciada por la escorrentía del agua dulce ([Acha et al., 2015](#)). Los frentes de corte son resultado de las diferencias de las tasas de movimiento de aguas entre los bordes y el centro del estuario. Cuando la marea crece, el agua en la parte central y profunda del estuario puede subir más rápido que el agua de los bordes la cual se ve afectada por la fricción del fondo ([O'Donnell, 1993](#)). Este tipo de frente puede coexistir con otros frentes o cambiar durante un ciclo de marea y será influenciado por la hidrología, la interacción entre los bordes y el fondo, así como por las características biogeoquímicas del estuario ([Acha et al., 2015](#)).

El estuario del Río de la Plata ([Figura 1](#)) es el receptor de la segunda cuenca hídrica más grande de América del Sur. La interacción de la pluma de descarga del Río de la Plata con la confluencia de las corrientes oceánicas de Brasil y Malvinas genera un frente de turbidez ([Piedra Cueva & Fossati, 2003](#)). La detección espacio-temporal del mismo es utilizada como una herramienta que permite comprender la dinámica hidrográfica de su zona de influencia físico-químico-biológica ([FREPLATA, 2005](#)). Su aplicación puede tener diferentes fines, desde gestión de los recursos hídricos, conservación biológica en todos los niveles, manejo y planificación estratégica de

actividades económicas tales como pesquerías u otras, hasta regulación de servicios ecosistémicos asociados con turismo y recreación ([Echevarría, 2016](#)).

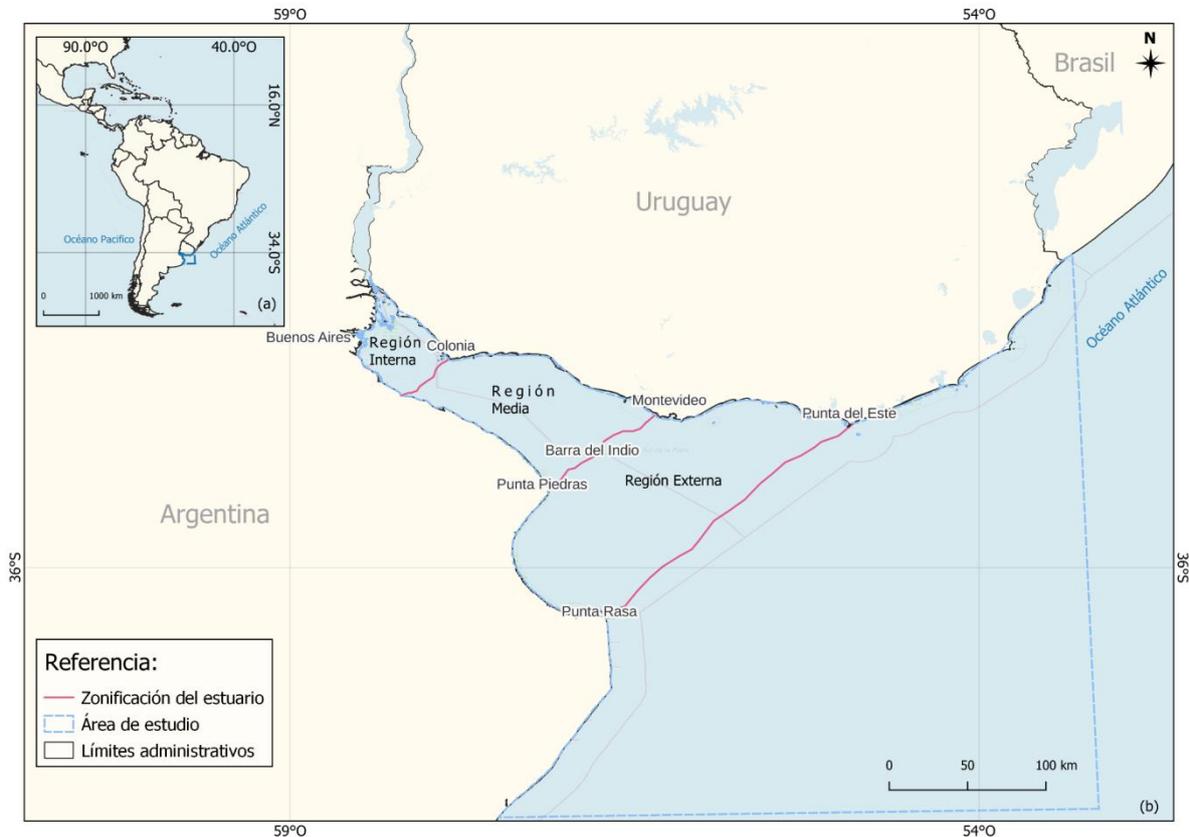


Figura 1. Ubicación geográfica del área de estudio en la región sur de Sudamérica (a) y zona de influencia del Río de la Plata, considerando sus regiones, interna, intermedia y externa (b).

Fuente: Elaboración propia

La teledetección es una herramienta aplicable para estimaciones de turbidez del agua, a partir de diferencias de color en el plano horizontal ([Dogliotti et al., 2014](#); [Maciel et al., 2021](#)). Por tanto, a partir de imágenes satelitales es posible detectar las dimensiones del frente de turbidez y su dinámica. Se han desarrollado diversas metodologías de detección de la turbidez del agua en estuarios. En 1999, se introdujo un enfoque basado en teledetección para estudiar la dinámica de los ríos Tinto y Odiel ([Olmo et al., 1999](#)). Este método utilizaba un análisis de componentes principales para

categorizar las aguas del sistema estuario-océano según su comportamiento hidrodinámico. Al combinar los resultados de teledetección con datos *in situ*, fue posible establecer la distribución espacial de las distintas categorías, proporcionando así una base sólida para entender la dinámica del estuario en su conjunto ([Olmo et al., 1999](#)). A su vez, [Hernández & Hernández \(2003\)](#) desarrollaron un modelo teórico a partir de datos *in situ* de la costa oriental de Gran Canaria, al cual incorporaron valores complementarios obtenidos a partir de técnicas de teledetección, principalmente utilizando histogramas de imágenes del programa Landsat para relacionar valores de reflectancia. Más adelante, en 2010, el Grupo de investigación de la Estación Biológica de Doñana presentó una metodología de predicción de turbidez a partir de datos obtenidos *in situ* los cuales fueron correlacionados con valores de reflectancia de imágenes satelitales Landsat. En este trabajo se destaca la importancia de los valores obtenidos en campo para representar la complejidad de la realidad, pero a su vez demuestran como técnicas de teledetección estiman de una manera rápida y sencilla algunos de los fenómenos físicos que presentan los estuarios, en contraposición a métodos tradicionales.

2. Antecedentes

2.1 Características biológicas y ecológicas de los estuarios

Los estuarios son zonas de relevancia biológica y ecológica debido al desarrollo de un ecosistema complejo y diferente al que se produce individualmente en cada uno de los dos sistemas involucrados (el fluvial y el marino), lo cual queda reflejado en la elevada producción primaria y la alta abundancia y diversidad de plancton (fitoplancton y zooplancton) distribuido en zonas estuarinas ([Acha et al., 2003](#)). Este

conjunto de condiciones ecológicas puede desencadenar impactos positivos tanto en la biodiversidad marino-estuarina como en actividades económicas desarrolladas en esa zona tales como pesquerías y actividades turísticas ([Echevarría, 2016](#))

2.2 Estuario del Río de la Plata

El origen del estuario Río de la Plata es debido a procesos tectónicos que se han mantenido estables en el tiempo ([Piccolo et al., 1997](#)). A partir de sus características geomorfológicas el Río de la Plata puede clasificarse como un estuario primario de influencia fluvial ([Piccolo et al., 1997](#)). Los estuarios de influencia fluvial son aquellos donde el valle no ha sido inundado por el mar y la circulación en los tramos inferiores del estuario se ve afectada por la marea ([Piccolo et al., 1997](#)). De acuerdo con su geomorfología, el Río de la Plata puede dividirse en tres zonas: interna, media y externa ([Boschi, 1987](#)) ([Figura 1](#)). La zona interna o cabecera del estuario, está caracterizada por la presencia de agua dulce, bajo influencia del delta subfluvial y sin influencia del agua salada, donde los sedimentos están integrados por arena fina, limo y arcilla. Su límite se define por una línea imaginaria que une las ciudades de La Plata con Colonia. La dinámica fluvial se hace visible al producirse una acumulación de arena a lo largo de las costas correspondientes a Uruguay y una escasez de las mismas sobre las costas argentinas que se caracterizan por ser playas de limo y arcilla. Las playas correspondientes a Argentina están apoyadas sobre un manto de tosca, el cual aflora en algunos puntos, formando un cordón litoral en la región bonaerense. La zona media del estuario abarca desde el límite de la zona interna hasta una línea imaginaria que une Punta Brava (Uruguay) con Punta Piedras (Argentina). La zona media se caracteriza por tener mayor influencia de las mareas y

el oleaje, permitiendo el ingreso de agua marina al sistema a través del fondo. Estas condiciones hacen posible que especies marinas puedan utilizar esta zona del estuario. La zona externa del estuario es donde se producen los mayores intercambios entre el sistema marino y el fluvial ([Boschi, 1987](#)). Esta zona está ubicada entre Punta del Este (Uruguay) y Cabo San Antonio (Argentina), pero estos límites son oscilantes dependiendo del desplazamiento del agua dulce y marina.

La dinámica del estuario del Río de la Plata está controlada por las olas impulsadas por la marea, el viento y la descarga continental, pero modificada por la topografía del fondo y la fuerza de Coriolis ([Gutiérrez, 2016](#)). El equilibrio entre estas fuerzas es muy variable, dependiendo en gran medida de la intensidad del viento y la descarga continental ([Burattiet al., 2022](#)). La descarga continental viene dada principalmente por los aportes de los ríos Paraná y Uruguay. En promedio son descargados 20.000 m³/s al Océano Atlántico ([Gutiérrez, 2016](#)). El agua dulce descargada por el Río de la Plata interactúa con las corrientes oceánicas de Brasil y Malvinas. La corriente de Malvinas es una corriente fría con dirección Noreste que circula a lo largo del talud continental argentino y cuyo brazo costero, que circula sobre la plataforma continental, es la corriente Patagónica. La corriente de Brasil es cálida y fluye con dirección Sur, circulando a lo largo de la costa de Brasil hasta la zona del Río de la Plata donde se aleja de la costa ([Angelescu & Sánchez, 1997](#)). El estuario cuenta con un régimen astronómico micro mareal con disparidades diurnas y grandes diferencias entre procesos de bajamar y pleamar contiguos ([FREPLATA, 2005](#)). Los vientos suelen ser leves con un promedio anual uniforme, aumentando aproximadamente 5 m/s en las zonas costeras ([Ré & Menéndez, 2003](#)). La mayor intensidad de los vientos ocurre en el sector sur y la menor en el sector noroeste. Un fenómeno de vientos intensos y

sostenidos que afecta a la costa son las “Sudestadas”, provienen desde el sudeste y alcanzan velocidades mayores a 30 m/s, asociados con tormentas que afectan durante varios días y que pueden generar inundaciones en el litoral del Río de la Plata ([Simionato et al., 2011](#)).

2.3 Frente de turbidez del Río de la Plata

La turbidez en el Río de la Plata tiene un rol central porque condiciona la entrada de luz a través de la columna de agua, lo cual impacta a diversos procesos biológicos, ecológicos y físico-químicos que allí acontecen ([Simionato et al., 2011](#)). La turbidez delimita el hábitat de algunas especies marino-estuarinas incluidas en diferentes niveles tróficos (desde productores primarios a consumidores superiores). Por ejemplo, la atenuación de la luz afecta el desarrollo de algunas especies de fitoplancton. También puede contribuir a cambios en la abundancia de especies de peces costeros de interés comercial, destacándose la corvina rubia (*Micropogonias furnieri*). Otra característica que se ve afectada por la turbidez es el estado de contaminación del río, ya que los sedimentos son la principal fuente de transporte de contaminantes acoplados, principalmente metales pesados que terminan ingresando en organismos vivos y son transportados a través de las diferentes tramas tróficas representando un potencial impacto sanitario sobre la población humana que consume productos pesqueros extraídos del Río de la Plata ([Simionato et al., 2011](#)).

El frente de turbidez del Río de la Plata es definido como el área donde se registra el máximo de sedimentos en suspensión, resultado de procesos físico-químicos y mecánicos asociados con la interacción entre la descarga de aguas continentales, las masas de aguas marinas de plataforma y la marea. A partir de un análisis de imágenes

satelitales diarias de NOAA para una serie temporal de cuatro años, [Framiñan et al \(1996\)](#) establecieron el desplazamiento máximo del frente de turbidez del Río de la Plata en el eje este-oeste, determinando que la posición más al oeste ocurre en verano, coincidiendo con el caudal mínimo de los ríos y predominio de vientos del noroeste. Mientras tanto, el máximo desplazamiento hacia el este lo alcanza en primavera, con fuertes vientos del suroeste. En cuanto a la variabilidad espacial del frente en el eje norte-sur, la misma se produce en otoño e invierno coincidiendo con el máximo registro de caudal de los ríos. Se observa una mayor variabilidad en la zona central del estuario y distribución bimodal frontal, destacando los puntos de mayor densidad frontal en la región de la Bahía de Samborombón y la porción meridional de Montevideo. La mayor variabilidad de desplazamiento del frente de turbidez ocurre en la costa uruguaya ([Framiñan et al., 1999](#)). La ubicación de los máximos de turbidez puede verse afectadas por variaciones en el régimen de mareas, descarga continental y procesos sedimentológicos ([Simionato et al., 2011](#)). [Framiñan et al., \(1999\)](#) plantearon que hay una relación entre la posición del frente y la estabilidad de la columna de agua, siendo que los máximos de turbidez coinciden con las áreas donde los gradientes verticales de salinidad son máximos. [Nagy \(2008\)](#) propone una clasificación de los frentes del estuario del Río de la Plata a partir de las diferencias de color. Estos frentes son: frente de turbidez principal, frente marino principal, frente marino secundario y frente de turbidez secundario. Recientemente, [Maciel et al \(2020\)](#) indicaron que la descarga del río es el principal factor que afecta la ubicación del frente de turbidez principal del Río de la Plata, seguido por el nivel del mar y los vientos locales.

2.4. Eventos El Niño/La Niña y caudal del Río de la Plata

El fenómeno El Niño Oscilación del Sur (ENOS) es un evento interanual de origen atmosférico-oceanográfico cuyo desarrollo inicial ocurre en el océano Pacífico y posteriormente se traslada hacia el resto del planeta ([Bidegain et al., 2017](#)). El ENOS presenta dos fases contrastantes, una cálida (El Niño) y otra fría (La Niña), y entre ambas una fase neutra. Durante El Niño ocurre el aumento de la temperatura superficial del mar y la disminución de los vientos alisios en el lado este del océano Pacífico. ([Franco et al., 2020](#)). Estas condiciones generan fuertes precipitaciones en el suroeste del Pacífico. Por su parte, durante La Niña ocurre el descenso de la temperatura superficial del mar y la intensificación de los vientos alisios en el este del océano Pacífico ([Maturana et al., 1997](#)). Durante las dos fases del ENOS se producen intercambios de calor entre el océano y la atmósfera afectando la temperatura media global y el ciclo hidrológico, lo cual puede promover situaciones de inundaciones (en fase El Niño) o sequías (fase La Niña) en la cuenca del Plata y diferentes partes del planeta.

Existe correlación positiva (negativa) entre el fenómeno El Niño (La Niña) y el aumento (disminución) de las precipitaciones y posteriormente del caudal fluvial en la cuenca del Plata ([INA, 2003](#)). El aumento o disminución del caudal y descarga fluvial en la cuenca del Plata tiene un efecto directo en la posición del frente de turbidez del Río de la Plata ([INA, 2003](#)). Durante El Niño, el frente de turbidez muestra su máximo desplazamiento hacia el noreste ([INA, 2003](#)). Inversamente, durante La Niña el frente de turbidez del Río de la Plata muestra su máximo desplazamiento hacia el suroeste ([INA, 2003](#)).

2.5 Estadística Bayesiana

La estadística Bayesiana es una rama de la estadística que permite establecer inferencias de datos desconocidos a partir de datos conocidos mediante un modelo paramétrico preestablecido, incorporando un enfoque probabilístico y una base matemática sólida ([García & González, 2018](#)). El fundamento clave de la estadística Bayesiana radica en el teorema de Bayes, el cual relaciona los datos observados con la probabilidad de los datos observados dado el parámetro (probabilidad verosímil) y la probabilidad previa o asumida del parámetro (probabilidad a priori), para estimar así la probabilidad posterior del parámetro dado los datos observados probabilidad a posteriori ([Blangiardo & Cameletti, 2015](#)). En suma, a través de la combinación de datos observados y una distribución de probabilidad a priori permite obtener una distribución de probabilidad a posteriori más precisa ([García & González, 2018](#)).

Matemáticamente, el teorema de Bayes se expresa como:

$$P(\theta|D) = P(D|\theta) * P(\theta) / P(D)$$

donde θ representa el parámetro desconocido, D son los datos observados, $P(\theta|D)$ es la probabilidad a posteriori, $P(D|\theta)$ es la probabilidad verosímil, $P(\theta)$ es la probabilidad a priori y $P(D)$ es la probabilidad de los datos ([Blangiardo & Cameletti, 2015](#)).

El teorema de Bayes proporciona el marco estadístico para actualizar las hipótesis iniciales a medida que se recopilan nuevos datos, lo que conduce a mejorar la estimación del parámetro de interés. Así se construye esta metodología que consta de tres pasos: i) definir un modelo de probabilidad que parta de datos conocidos (observados), ii) actualizar los parámetros seleccionados y iii) evaluar un ajuste al modelo a partir de la sensibilidad a los cambios que pudieran sufrir los parámetros

con la incorporación de nuevos datos.

La estadística bayesiana ofrece un enfoque flexible y poderoso para hacer inferencias estadísticas al incorporar conocimiento previo y datos observados de manera coherente. Su capacidad para actualizar creencias y adaptarse a modelos complejos la convierte en una herramienta valiosa cuando se requiere una estimación precisa y razonamiento probabilístico ([Rendón-Macías, 2018](#))

2.6 Teledetección

La teledetección es la observación a partir de imágenes de la superficie de la Tierra adquiridas a través de sensores remotos, como son los satélites ([ESA, 2009](#)). La captura de datos a partir de esta técnica conlleva la medición de la energía que es reflejada o emitida por los objetos. Esta energía electromagnética, se propaga como ondas que se diferencian entre ellas por su longitud, distancia entre dos crestas sucesivas de una onda ([Figura 2](#)) Cada objeto o grupo de objetos refleja un único espectro de longitudes de onda, denominado firma espectral que sirve para distinguir un objeto de otro ([Chuvienco, 1991](#)) ([Figura 2](#)).

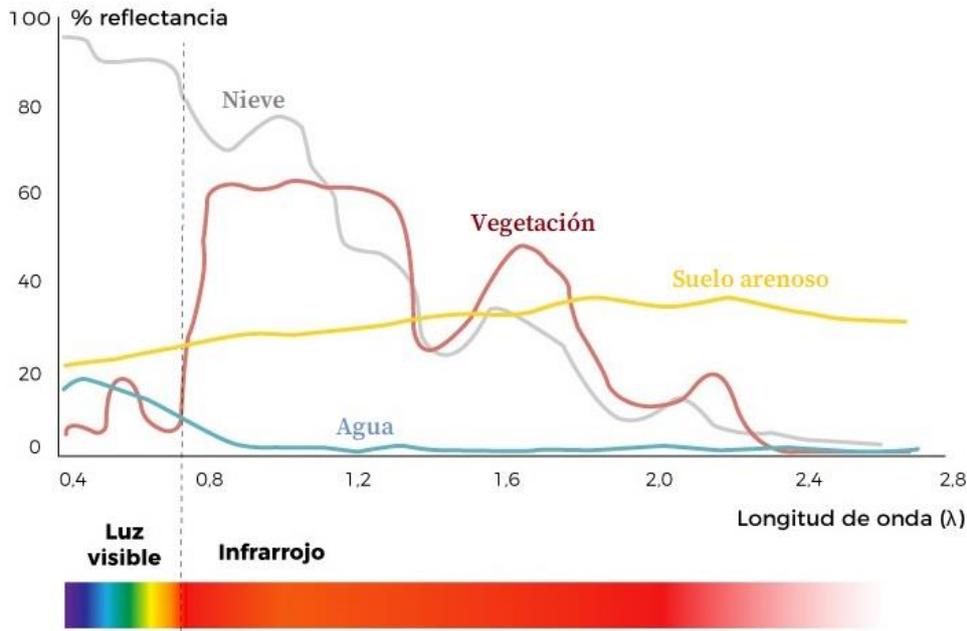


Figura 2: Representación gráfica del espectro electromagnético y firmas espectrales para coberturas de nieve (gris), vegetación (rojo), suelo arenoso (amarillo), agua (celeste). Fuente: Imagen adaptada de eduSat Universidad de Girona.

La utilización de sensores montados en satélites espaciales sirve para captar diferentes longitudes de onda emitidas o reflejadas por objetos en la superficie del planeta. Para la observación remota de recursos naturales se utilizan satélites con órbitas helio-sincrónicas ([Figura 3](#)) con el objetivo de obtener imágenes de la misma porción de la Tierra en condiciones de luz homogéneas permitiendo así una comparación temporal ([Sánchez & Toral, 2014](#)).

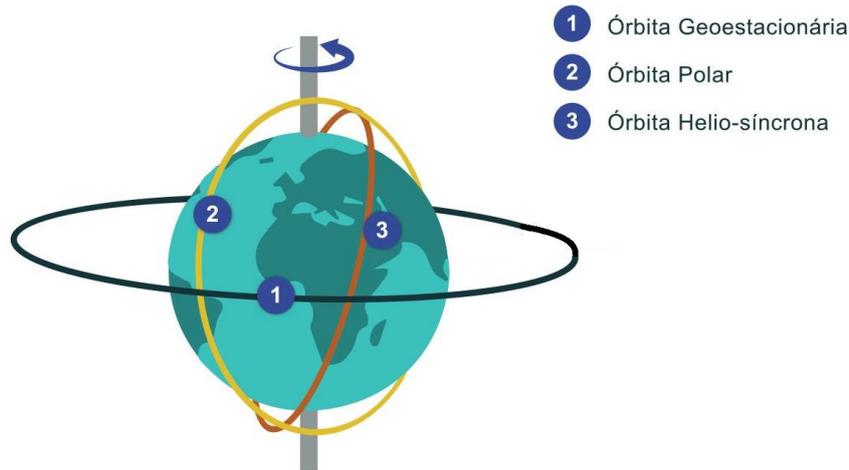


Figura 3: Tipos de órbitas satelitales. Órbita geoestacionaria (1), órbita polar (2), órbita heliosincrónica (3). Imagen adaptada de © 2015 SOPHIA.

El satélite Aqua (<https://modis.gsfc.nasa.gov/>) órbita con una inclinación de 98° a una altitud media de 705 km en dirección ascendente, lleva a bordo el sensor “Moderate Resolution Imaging Spectroradiometer” (MODIS) y monitorea la totalidad de la superficie terrestre con una frecuencia de 1 o 2 días, variando según la latitud ([Vermote, 2015](#)).

El sensor MODIS posee una sensibilidad radiométrica alta, 12 bits en 36 bandas espectrales dentro del rango de $0.4 \mu\text{m}$ a $14.4 \mu\text{m}$ de longitud de onda. Este sensor es de barrido con un espejo móvil que oscila perpendicularmente a la dirección de la trayectoria a un ángulo de $\pm 55^\circ$ lo que permite explorar el terreno a ambos lados de la traza del satélite. La franja de escaneo es de 2.330 km ortogonal por 10 km a lo largo de la órbita helio-sincronica casi polar. Posee una resolución espacial de 250 m en las bandas 1 y 2, 500 m en las bandas 3 a 7 y 1000 m en las bandas 8 a la 36 ([Vermote, 2015](#)).

Las imágenes producto de este sensor se encuentran disponibles de forma libre en la plataforma Google Earth Engine (<https://code.earthengine.google.com>). Esto permite un monitoreo del área de estudio continuo y prolongado en el tiempo.

Además de los trabajos ya mencionados encontramos diversas metodologías que incorporan a la teledetección como herramienta para el análisis de la concentración de turbidez y dinámica del frente de turbidez principal del Río de la Plata. [Dogliotti et al. \(2014\)](#) presentó un estudio a partir del análisis de algoritmos para imágenes satelitales utilizando datos de las bandas del infrarrojo cercano e infrarrojo medio para el estudio de la turbidez del agua y sólidos en suspensión, donde se comparó con valores *in situ*. Se llegaron a buenos resultados con un algoritmo global, pero se recomienda hacer ajustes con valores locales.

[Dogliotti et al. \(2016\)](#) planteó una metodología para el estudio de la variabilidad espacio temporal de la concentración de turbidez en el Río de la Plata. Esta metodología se caracteriza por utilizar una serie temporal de largo plazo (15 años) a partir de datos MODIS. El objetivo de este estudio es estimar valores de turbidez en el estuario del Río de la Plata y entender el impacto de la Oscilación Austral de El Niño (ENSO) en la misma a escala estacional e inter-anual. Para esto se combinaron técnicas de teledetección con mediciones *in situ*. Posteriormente [Ruiz \(2017\)](#) aplicó una metodología para detección de sólidos en suspensión a partir de imágenes satelitales calibradas con datos de campo. Este estudio dejó en evidencia las limitaciones implicadas al momento de extrapolar modelos calibrados a partir de datos de campo en zonas donde no se cuentan con este tipo de datos para calibrar al modelo.

Por otro lado, [Maciel et al. \(2021\)](#) implementaron un algoritmo basado en imágenes satelitales para detectar de forma remota el frente de turbidez del Río de la Plata. El algoritmo utilizó la reflectancia valor del tope de la atmósfera en la banda roja del satélite MODIS-Aqua. El estudio analizó la dinámica del frente combinando información de teledetección y datos de series temporales de caudal de río, vientos, salinidad y nivel del mar, en el periodo 2014-2017. Los autores indican que la descarga es el principal forzamiento externo, mientras que el nivel del mar es un forzante secundario, destacando que los vientos locales debían tener un componente de al menos 2 días en determinada dirección para afectar la ubicación del frente de turbidez principal

3. Justificación

El frente de turbidez principal del Río de la Plata se revela como un elemento clave para entender la compleja interacción entre factores naturales (físicos, astronómicos, hidrológicos) y perturbaciones interanuales extremas que afectan la dinámica de este estuario. La detección y seguimiento interanual del frente de turbidez principal representa un eslabón clave para complementar el conocimiento acerca de la dinámica espacio-temporal de este estuario y a su vez, contribuye al monitoreo del proceso adaptativo que pueda experimentar el estuario ante variabilidad extrema de las condiciones hidrológicas y atmosféricas en el futuro.

A partir de esto nace la inquietud de emplear una metodología que fusiona técnicas de estadística Bayesiana y análisis de imágenes satelitales, se busca detectar y cuantificar la evolución del frente de turbidez en el Río de la Plata. Esta integración de enfoques cualitativos y cuantitativos promete proporcionar una visión de la dinámica del frente de turbidez en esta región estratégica.

Esta investigación busca contribuir al desarrollo del conocimiento en geografía marina y estuarina, al aportar una visión más detallada sobre la localización, distribución e interacción de fenómenos marinos complejos, enriqueciendo así la comprensión integral de los procesos costeros y marinos en los estuarios.

El conocimiento de estas dinámicas es crucial para la toma de decisiones relacionadas con la conservación biológica y el desarrollo económico en las áreas estuarinas. En un contexto donde la pesca, el turismo y otras actividades económicas dependen intrínsecamente de la salud de los estuarios, comprender los patrones espaciales de turbidez brinda una base sólida para implementar prácticas sostenibles

y estrategias de adaptación.

4. Preguntas de investigación

1. ¿Cuál es la variabilidad espacial extrema del frente de turbidez principal del Río de la Plata asociada a eventos La Niña/El Niño?
2. ¿El comportamiento espacial del frente de turbidez principal del Río de la Plata puede ser representado mediante un modelo basado en estadística Bayesiana?

5. Hipótesis.

Son planteadas dos hipótesis de investigación.

1. Los eventos El Niño/La Niña tienen un efecto directo en la variabilidad espacial extrema del frente de turbidez principal del Río de la Plata, afectando tanto su posición como su dinámica.
2. La variabilidad espacial del frente de turbidez puede ser modelada a partir de variables explicativas tales como el viento (dirección, velocidad), la marea y el caudal, a partir de modelos basados en estadística Bayesiana.

6. Objetivos

6.1 Objetivo general.

Evaluar la dinámica espacial del frente de turbidez principal del estuario del Río de la Plata en períodos interanuales de variabilidad extrema asociados a eventos El Niño/La Niña.

6.2 Objetivos específicos

- Representar cambios de la posición del frente de turbidez principal del sistema estuarial del Río de la Plata en periodos interanuales de variabilidad extrema asociados a eventos El Niño/ La Niña.
- Aplicar una metodología semi-cuantitativa para detección del frente de turbidez principal del Río de la Plata.

7. Materiales y Métodos

7.1 Área de estudio

El Río de la Plata se encuentra ubicado en la costa este de Sudamérica entre Argentina y Uruguay, entre los 34°00'S, 36°10'S y los 55°00', 58°10' W. Este sistema estuarino está conformado a partir de la descarga de los ríos Paraná y Uruguay, y representa el colector de la segunda cuenca más grande del continente. La superficie del Río de la Plata se estima en 38.800 km², con 250 km de largo aproximadamente y un ancho que varía entre 40 km en la parte más estrecha y 200 km en la desembocadura cuya conexión es directa al océano Atlántico (Serrano, 2014).

El área de interés para la presente investigación fue la región externa del Río de la Plata por ser la zona a través de la cual se desplaza el frente de turbidez principal y donde se observan sus principales cambios espacio-temporales ([Figura 1](#)). Esta región se caracteriza entonces por tener contacto directo con el océano por lo que las concentraciones salinas son máximas en la columna de agua con una capa superficial menos salina. La granulometría tiende a ser más gruesa debido a las corrientes marinas y el aporte de sedimento del río [Bernden, \(2016\)](#). Las variables ambientales seleccionadas para esta investigación fueron viento, marea y caudal las cuales se encuentran desarrolladas en la sección 7.2.2.

7.2 Base de datos

7.2.1. Variable respuesta: Reflectancia

La extracción de datos se realizó a partir de imágenes MODIS Aqua MYD09A1 Versión 6 obtenidas desde la Agencia Nacional de Administración Espacial (NASA por sus siglas en inglés, (<https://lpdaac.usgs.gov/node/>)). Estas imágenes son resultado de una composición de 8 días de valores de reflectancia espectral. Cuentan con correcciones atmosféricas para la dispersión de Rayleigh (fenómeno responsable de la dispersión de la luz solar en la atmósfera ([Schowengerdt, 2006](#))), gases y aerosoles. Presentan una resolución espacial de 500 m con dimensión geográfica de 1200 km x 1200 Km.

Las imágenes de MODIS se proporcionan en reflectancia de superficie escalada, que puede convertirse en reflectancia de superficie mediante la fórmula:

$$\rho(\lambda) = ND * 0.0001$$

donde:

ND: Número digital de las bandas MODIS.

A partir de los datos obtenidos de las imágenes se creó una matriz con los valores de reflectancia de la banda roja, banda que abarca entre 620-670 nm del espectro electromagnético y donde el agua clara y el agua turbia presentan una mayor diferencia en su firma espectral ([Figura 4](#)) fecha, coordenadas, identificador del punto dentro de la imagen e identificador del punto dentro de la serie de datos.

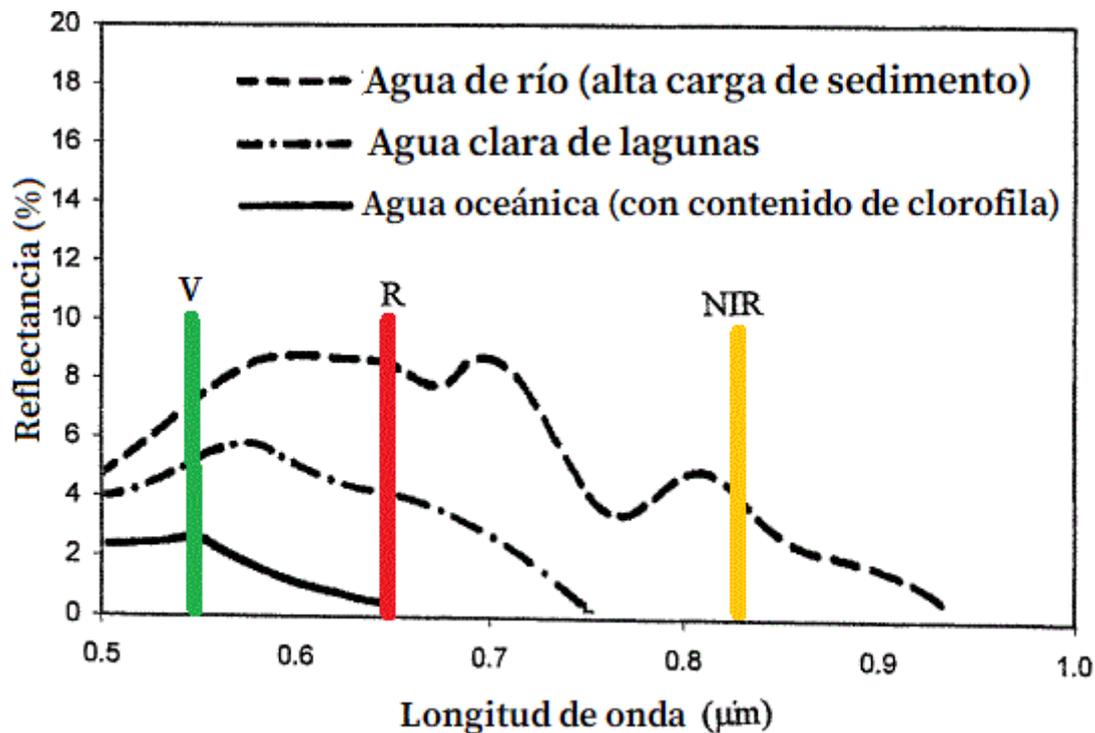


Figura 4: Firma espectral del agua de río cargada en sedimento en línea con guiones firma espectral de agua clara léntico en línea de guion con punto y firma espectral de agua oceánica con línea continua. Se grafica valor medio de la longitud de onda correspondiente al verde (V) y rojo (R) del espectro visible, y del infrarrojo cercano (NIR) Fuente: imagen adaptada de Mather et al (1993)

7.2.2. Variables explicativas

Las variables explicativas (independientes) consideradas para la modelización correspondieron a los siguientes factores atmosféricos, astronómicos o hidrológicos: viento (velocidad y dirección), marea y caudal.

7.2.2.1. Viento

El viento posee un impacto directo sobre la pluma de agua dulce del Río de la Plata por lo que se observa una variabilidad estacional e interanual ([Simionato et al., 2001](#)).

La variabilidad interanual está dada por dos variantes. La primera y que explica la mayor varianza está dada en un periodo de dos años y está vinculada con los cambios

de temperatura superficial del oeste en el Pacífico Tropical. La segunda variante está asociada a la rotación horaria/antihoraria de los vientos en periodos de entre ocho y doce años ([Simionato et al., 2001](#)). Según [Meccia et al., \(2018\)](#), durante los periodos El Niño/La Niña ocurre predominancia de vientos de componente oeste/este.

Los datos de vientos fueron cedidos por el Instituto Uruguayo de Meteorología (INUMET) para su utilización en esta tesis. La base de datos proporcionada contaba con los datos de velocidad (km/h) y dirección (°) por día para el período 2011- 2019, tomados en las estaciones meteorológicas de Colonia del Sacramento y Montevideo (Melilla). A partir de datos diarios fue creada una matriz con el promedio de cada parámetro para el periodo de 8 días, con el fin de ajustarse a la escala temporal que abarcan las imágenes satelitales de Aqua-MODIS.

7.2.2.2. Marea

La marea es la oscilación periódica del nivel medio del mar debido a las interacciones gravitatorias del Sol y la Luna con la Tierra. Los movimientos de marea son movimientos verticales y horizontales que generan las corrientes de marea. Hay una profundidad donde las mareas comienzan a mezclar la columna de agua en dirección a la costa, generando entre la región de aguas mezcladas y la región oceánica el frente de marea ([Acha et al 2015](#)). Las mareas, que son semidiurnas en esta región (con dos ciclos diarios de pleamar y bajamar), generan variaciones en el nivel del agua que afectan la dirección y velocidad de las corrientes. Estas variaciones inciden en la mezcla de aguas dulces provenientes de los ríos Paraná y Uruguay con las aguas saladas del Atlántico, determinando la extensión y posición del frente de turbidez en el estuario ([Farias, 2022](#)).

Los datos de marea fueron obtenidos de la página web Tabla de Mareas (<https://tablademareas.com/>). Se tomaron los datos del primer registro del día expresado en metros y se realizó un promedio de los 8 días correspondientes al producto MODIS utilizado. Se trabajó con los datos de los puntos de Colonia y Montevideo.

7.2.2.3 Caudal

El caudal, refiere al volumen de agua que pasa por segundo en un punto observado. Durante eventos El Niño/La Niña se observan anomalías positivas/negativas de precipitación en la Cuenca del Plata lo cual se ve reflejado en aumento/disminución del caudal del Río de la Plata ([Meccia et al., 2008](#)).

Los datos de caudal para el periodo 2011-2014 fueron obtenidos desde el Instituto Nacional del Agua (Argentina). Se utilizaron los datos de estimaciones diarias de los tres principales tributarios al Río de la Plata: Paraná Guazú, Paraná de las Palmas y Uruguay. De la suma del caudal de los tres puntos se realizó el promedio de los 8 días correspondientes al producto Aqua-MODIS

7.3 Análisis de datos

El análisis espacial del frente de turbidez principal del Río de la Plata fue concretado a partir de imágenes satelitales en la banda del rojo en el espectro visible, velocidad del viento, valor de marea y caudal. Específicamente fue considerado el período 2012-2016, correspondiente a variabilidad extrema del frente de turbidez, asociados con eventos El Niño/La Niña de gran intensidad.

7.3.1 Elección de escala temporal

Los periodos de análisis para los eventos ENOS y sus fases positiva (El Niño) y negativa (La Niña) fueron seleccionaron sobre la base del Índice “Multivariate El Niño/Southern Oscillation index” (MEI, por sus siglas en inglés) El índice MEI es calculado a partir de la función ortogonal empírica de la serie temporal de 12 estaciones donde se miden cinco variables: presión del nivel del mar, temperatura de la superficie del mar, vientos zonales superficiales, vientos meridionales superficiales y radiación de onda larga. Las mediciones de estas variables se calculan para la cuenca del océano Pacífico Tropical. Los valores son presentados de forma bimensual con el objetivo de tener en cuenta los efectos estacionales del ENOS y reducir el efecto interestacional ([NOAA, 2022](https://www.noaa.gov/enso/mei)). Los valores positivos a partir de 0.5 son considerados como eventos El Niño y a partir de - 0.5 son considerados eventos La Niña.

Tabla 1: Valores del Índice MEI Multivariado Versión 2 (MEI.v2) para eventos El Niño/La Niña. En rojo son indicados los valores del índice correspondientes al evento **El Niño** y en azul los correspondientes al evento **La Niña** (fuente: <https://www.psl.noaa.gov/enso/mei>).

Año	Dic- Ene	Ene- Feb	Feb- Mar	Mar -Abr	Abr- May	May -Jun	Ju- Jul	Jul- Ago	Ago -Set	Set- Oct	Oct- Nov	Nov -Dic
2011	-1.9	-1.6	-1.8	-1.7	-1.3	-1.1	-0.9	-0.9	-1.2	-1.4	-1.2	-1.2
2012	-1.1	-0.7	-0.6	-0.4	-0.4	-0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.1
2013	-0.1	-0.1	-0.1	-0.4	-0.7	-1.2	-0.9	-0.5	-0.4	-0.2	-0.2	-0.4

2014	-0.5	-0.4	-0.1	-0.2	-0.2	-0.1	0.3	0.2	-0.2	0.1	0.3	0.3
2015	0.2	0.05	0.1	0.4	1.0	1.8	1.7	1.9	2.2	2.1	1.9	1.9
2016	2.0	1.8	1.3	1.3	1.3	0.4	-0.5	-0.3	-0.3	-0.6	-0.5	-0.3
2017	-0.4	-0.4	-0.6	-0.2	0.2	-0.3	-0.7	-0.8	-0.8	-0.6	-0.6	-0.7
2018	-0.8	-0.7	-0.8	-1.3	-0.9	-0.5	-0.2	0.4	0.5	0.4	0.3	0.1
2019	0.08	0.5	0.8	0.3	0.3	0.4	0.3	0.3	0.2	0.3	0.5	0.4

Se establecieron tres escalas temporales de análisis. Trimestral, cuatrimestral y semestral. El evento El Niño tiene sus años de mayor intensidad en 2015 y 2016. Para el año 2015 la mayor intensidad se encuentra en el segundo semestre del año (julio a diciembre) y para el año 2016 en el primero (enero a julio).

Según los criterios previamente establecidos la escala temporal de cuatro meses quedó definida julio agosto octubre y noviembre para 2015 y enero, febrero, abril y junio para 2016. En este caso no se contó con imágenes libres de nubes para el mes de mayo por lo que fue excluido del análisis. La escala trimestral quedó definida de agosto a octubre para 2015 y de febrero a abril para 2016 (meses con mayor intensidad en cada uno de los años).

Los años de mayor intensidad son 2011 y 2012 para el evento La Niña ([Tabla 1](#)). En ambos casos se observa la mayor intensidad de la señal (valores de MEI más altos) en los primeros seis meses del año que son los que se seleccionaron para la escala temporal semestral. Para la escala temporal de cuatro meses se seleccionaron dos meses correspondientes a una estación del año y dos meses a la estación consecutiva, con la finalidad de equiparar los efectos estacionales descartando el mes de transición de estación. Para la escala trimestral se tomaron dos meses de

estaciones del año diferentes y el mes de transición para evaluar la incidencia de este en los resultados finales. Así es que el periodo trimestral fue definido de febrero a abril para los años 2011 y 2012; el cuatrimestre enero, febrero, abril y mayo y semestral de enero a junio ([Tabla 2](#)).

Tabla 2: Meses seleccionados para el análisis de los eventos El Niño/La Niña por escala temporal.

Evento	Año	Meses seleccionados por escala temporal		
		3 meses	4 meses	6 meses
La Niña	2011	Febrero	Enero	Enero
		Marzo	Febrero	Febrero
		Abril	Abril	Marzo
			Mayo	Abril
				Mayo
				Junio
	2012	Febrero	Enero	Enero
		Marzo	Febrero	Febrero
		Abril	Abril	Marzo
			Mayo	Abril
				Mayo
				Junio

Evento	Año	Meses seleccionados por escala temporal		
		3 meses	4 meses	6 meses
El Niño	2015	Agosto	Julio	Julio
		Setiembre	Agosto	Agosto
		Octubre	Octubre	Setiembre
			Noviembre	Octubre
				Noviembre

				Diciembre
2016	Abril	Marzo	Marzo	
	Junio	Abril	Abril	
	Julio	Julio	Junio	
		Agosto	Julio	
			Agosto	
			Setiembre	

7.3.2 Procesamiento de imágenes satelitales

Para realizar el procesamiento de las imágenes se utilizó la plataforma Google EarthEngine (<https://code.earthengine.google.com>). La plataforma Google Earth Engine se caracteriza por tener petabytes en colecciones de imágenes que permite realizar los procesamientos en la nube a través de lenguajes de programación como JavaScript o Python, generando procesos automatizados y minimizando el tiempo de procesamiento ([Google Earth Engine, 2023](#)).

El esquema de trabajo que fue aplicado para el procesamiento de las imágenes satelitales se encuentra descrito en la [Figura 5](#).

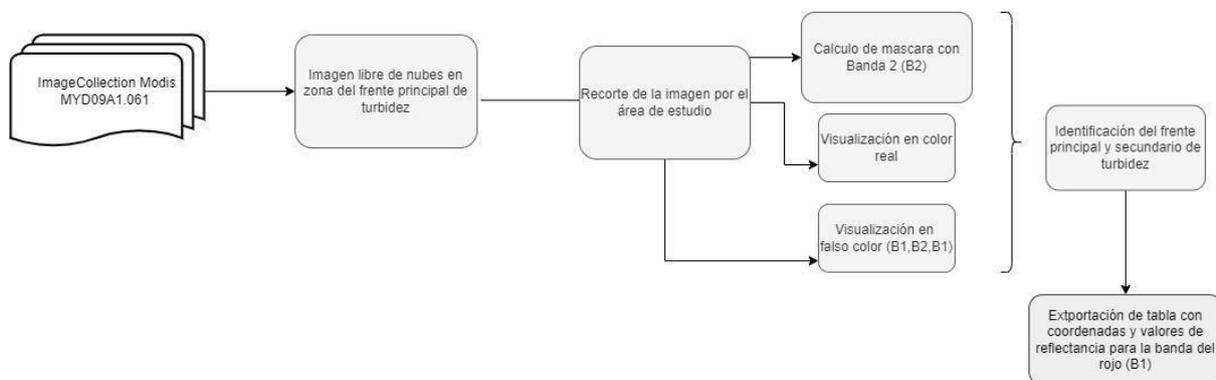


Figura 5. Procesos de análisis y detección del frente para obtener valores de reflectancia.

El primer paso fue seleccionar la colección de imágenes Aqua-MODIS a utilizar. Se seleccionaron las imágenes libres de nubes y se procedió delimitar el área de estudio para cada imagen, utilizando la función de recorte "*clip*", la cual permite extraer el área de intersección entre un shapefile con el contorno del área de estudio y la imagen en cuestión.

Se realizó una máscara basada en la banda en el espectro visible rojo entre las longitudes de onda 620-670 nm que permite clasificar la imagen en dos clases. Zonas con turbidez y agua clara.

Para el proceso de identificación de la posición del frente de turbidez principal se creó una geometría tipo punto para cada imagen seleccionada. La identificación comenzó por los extremos norte y sur del frente y luego se marcaron 10 puntos adicionales a lo largo del eje central. El mismo procedimiento se realizó con la zona externa al frente principal de turbidez. Generando un total de 24 puntos por imagen.

Fueron establecidas las coordenadas geográficas (latitud, longitud) por punto y el valor de reflectancia por píxel, para todos los puntos en el eje central del frente de turbidez. Estos datos fueron almacenados para su posterior uso (formato: .csv).

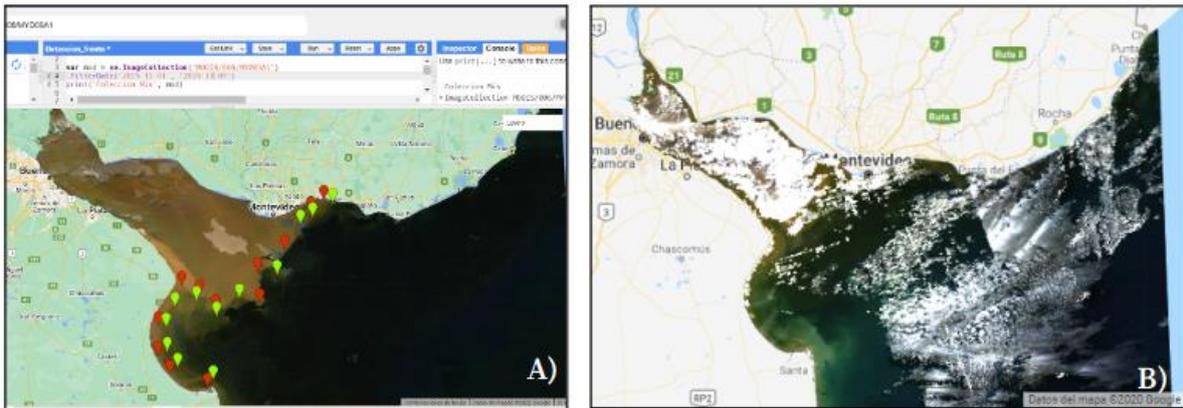


Figura 6: A) Puntos rojos límites de frente principal de turbidez, puntos verdes zona del frente de turbidez secundario. B) Ejemplo de imagen descartada por alto porcentaje de nubosidad.

Las imágenes que contaban con alto porcentaje de nubosidad, como muestra la [Figura 6.B](#), fueron descartadas ya que impiden la identificación del límite del frente de turbidez.

7.3.4 Exploración de datos

Se llevó a cabo un análisis exploratorio de los datos, iniciando con la representación gráfica de las variables explicativas (marea, dirección de viento, velocidad de viento y caudal) y de la variable respuesta (reflectancia) ([Figura 7](#)). En segundo lugar, se procedió a identificar y extraer los valores atípicos detectados por variable. Se efectuó una evaluación visual con el propósito de verificar que los datos no exhiben patrones o estructuras discernibles que pudieran sesgar los resultados del análisis. Este procedimiento fue aplicado para las bases de datos de los eventos El Niño y La Niña en sus tres escalas temporales.

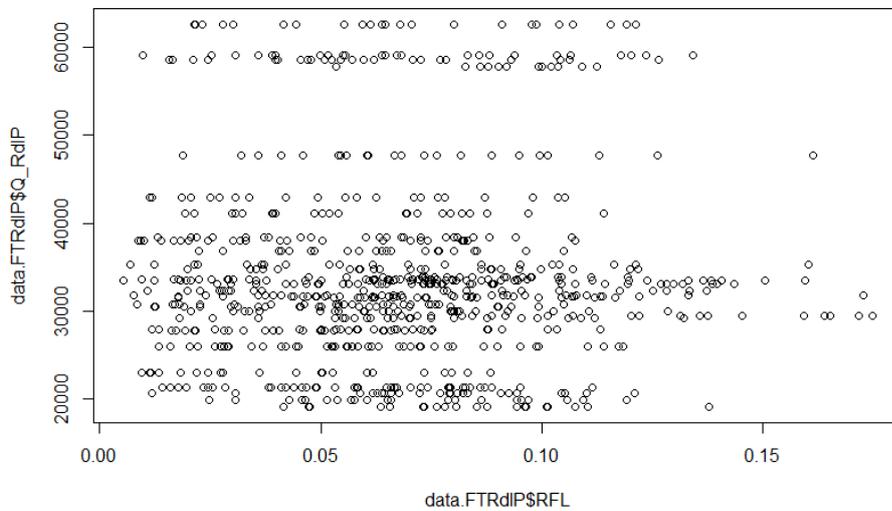


Figura 7: Ejemplo de representación gráfica de variable caudal (eje y) con los valores de reflectancia (eje x).

7.3.4.2 Correlación entre variables explicativas

Con el fin de analizar el grado de correlación existente entre las variables explicativas fue aplicado el test de Pearson ([Lalinde et al.,2018](#)). Siguiendo los resultados de la matriz de correlación fue posible seleccionar las variables físicas a utilizar ([Tabla 4](#)).

7.4 Modelización espacio-temporal

7.4.1. Modelos jerárquicos y aproximación R-INLA

Una de las herramientas utilizadas para el tratamiento de grandes volúmenes de datos son los modelos jerárquicos. Se trata de modelos probabilísticos complejos formulados como combinaciones de diversos componentes o colecciones de variables, capaces de adaptarse mediante simulación y a través del desarrollo de técnicas inferenciales. Los modelos jerárquicos tienen la capacidad de introducir factores de confusión indeterminados y de combinar fuentes de variabilidad y además, unir modelos parciales. A su vez, a partir del enfoque Bayesiano es posible transferir

información desde los datos observados y factores asociados hacia otro conjunto de datos mediante el aprendizaje generado por el modelo acerca de los parámetros. La Aproximación INLA ofrece un enfoque general para calcular las distribuciones marginales posteriores de todos los parámetros involucrados en el modelo. Para la tipología de modelos gaussianos latentes, tales como modelos espaciales, INLA logra establecer aproximaciones precisas de la densidad marginal posterior de los hiperparámetros y es capaz de representar las condicionales completas de las marginales posteriores de las variables latentes de manera rápida y eficiente ([Monsalve, 2013](#)). Su aplicación es relevante para los modelos jerárquicos espaciales, porque permite que tanto las observaciones como los parámetros del modelo sean variables aleatorias, dando como resultado estimaciones más realistas y precisas de la incertidumbre. Este tipo de modelación se destaca porque permite incorporar la autocorrelación espacial ([R -INLA Project](#)).

El paquete computacional INLA montado en la plataforma R (R-INLA) presenta una función principal `-inla()` mediante una fórmula que especifica el modelo que se va a ajustar, permitiendo incluir variables independientes y otras especificadas. R-INLA permite crear modelos espaciales, es decir trabajar con datos con alto grado de autocorrelación por cercanía ([R -INLA Project](#)). En este estudio, la función `inla()` fue utilizada para generar y ajustar modelos espaciales y también para generar modelos que incorporan variables explicativas relacionadas con factores físicos junto con la variable respuesta, reflectancia. La evaluación y comparación de estos modelos por evento dentro de una misma escala temporal permitieron obtener una comprensión más profunda de la variabilidad espacial y temporal de la reflectancia en el área de estudio.

La función $\text{inla}()$ da como resultado un modelo ajustado e información asociada incluyendo intervalos de confianza y el dato del criterio de información de la desviación del modelo (DIC) lo que permitió evaluar y comparar los modelos por evento dentro de una misma escala temporal ([Blangiardo, 2015](#))

7.4.1 Procesamiento R-INLA

Una vez seleccionadas las variables explicativas a utilizar y habiendo depurado los valores atípicos, fue posible representar la distribución espacial de los puntos con los datos asociados. Estos se grafican en el espacio geográfico y de esta manera se genera un perímetro que abarquen todos los puntos mencionados anteriormente, como muestra la [Figura 8](#).

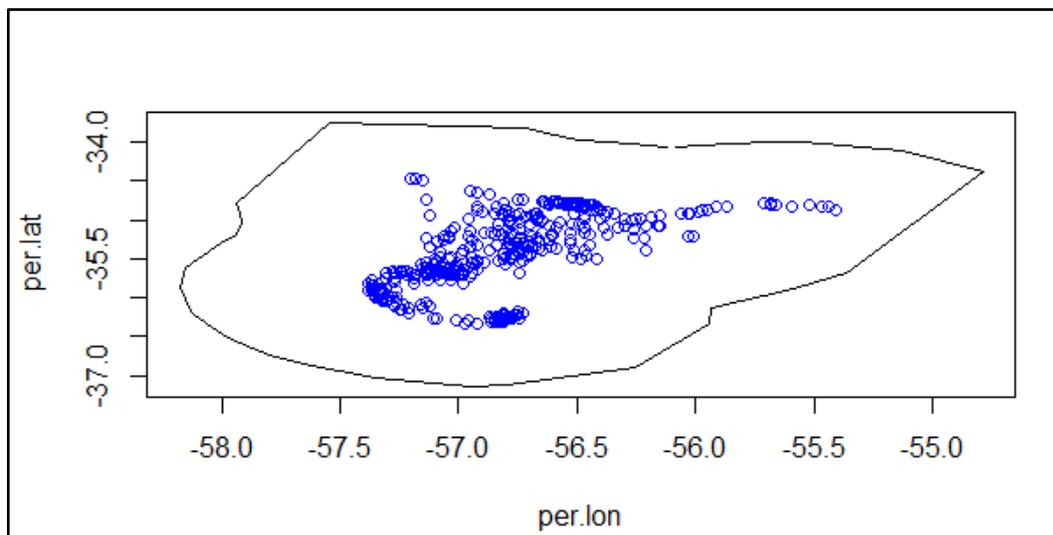


Figura 8: Ejemplo de perímetro de área de estudio.

A partir de este perímetro se realiza una grilla con celdas de $0.01^\circ \times 0.01^\circ$ como muestra la figura 6 con la finalidad de estimar el efecto espacial. ([R – INLA Project](#))

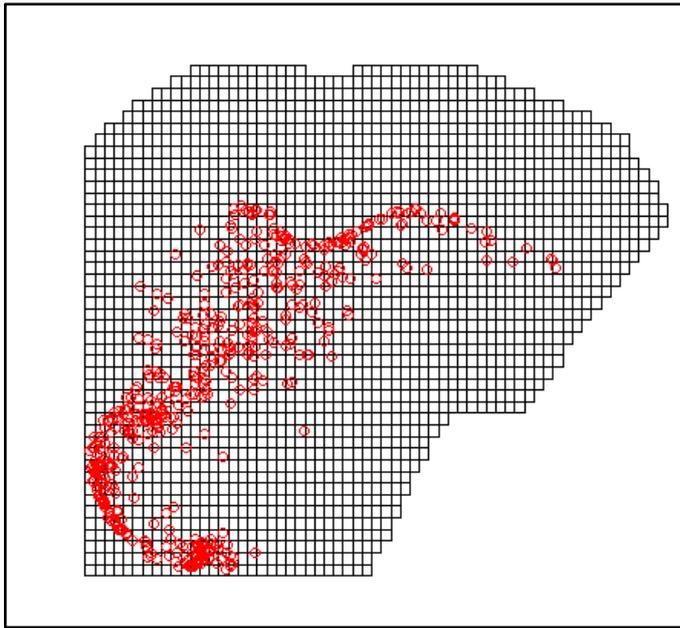


Figura 9: Grilla de estimación del efecto espacial.

Una vez generada la grilla se establece la fórmula que se quiere aplicar. La estructura de la fórmula es la siguiente:

fórmula<- y ~ 1 + z + f(x1, model = "...")+ f(x2, model = "...");

donde “y” representa la variable respuesta, “z” los efectos fijos y las funciones f(.) representan los componentes Gaussianos con efectos aleatorios del modelo. ([Miras, 2019](#)).

Para este trabajo se utilizó el modelo Markov random field (besag) para la variable respuesta (reflectancia) y random walk de orden 2 (rw2) para las variables explicativas. El modelo besag define una distribución a priori CAR. Es decir, $x \sim N(0, [TR]-)$, donde T es el parámetro de precisión y R es la matriz espacial adyacente de dependencias entre vecinos. Este modelo impone la restricción de suma cero $\sum_{k=1}^n x_k = 0$ (constr=TRUE). ([Miras, 2019](#)). El modelo rw2 se construye suponiendo

incrementos independientes de segundo orden y es utilizado para análisis espaciales donde los datos a predecir se encuentran a una distancia uniforme. ([R-INLA project](#)). Luego se aplica la función `inla()` donde se define las celdas con falta de información (NA). Así el modelo realizará la predicción para las celdas de interés, se define la familia de datos en este caso gaussiana y la fórmula a aplicar. Para responder a los objetivos planteados se definieron 16 modelos que se enumeran a continuación. Un modelo espacial, que genera el modelo a partir de la correlación espacial de los datos de reflectancia y un modelo para cada variable explicativa independiente. En una segunda etapa se establecieron modelos sumando dos variables explicativas. Luego modelos con combinaciones de tres variables y un último modelo con las cuatro variables explicativas ([Tabla 3](#)).

Tabla 3: Lista de variables explicativas incorporadas en los modelos de eventos El Niño/La Niña.

Modelo	VARIABLES INCORPORADAS
Espacial	Coordenadas (latitud y longitud)
univariados	Dirección del viento
	Velocidad del viento
	Caudal
	Marea
Bivariados	Velocidad del viento, caudal
	Dirección del viento, caudal
	Marea, caudal
	Dirección del viento, Velocidad del viento
	Velocidad del viento, marea
	Dirección del viento, marea
Trivariados	Dirección del viento, caudal, marea
	Marea, dirección del viento, velocidad del viento
	Caudal, dirección del viento, velocidad del viento
	Velocidad del viento, caudal, marea
Tetravariado	Velocidad del viento, Dirección del viento, marea, caudal

Una vez ejecutados los modelos se rescata la media de cada celda con el fin de generar la representación gráfica de cada uno de ellos.

7.5 Evaluación de modelos

7.5.1 Criterio de Información de Desviación

Para evaluar y seleccionar los modelos con mayor rendimiento, se emplearon los valores resultantes del Criterio de Información de Desviación. El DIC constituye una métrica que evalúa tanto la complejidad como el ajuste de los modelos, permitiendo así la comparación de modelos jerárquicos de alta complejidad basándose en su desviación. La obtención de valores más reducidos de DIC indica un rendimiento mejorado en cuanto a la relación entre la complejidad del modelo y su capacidad de ajuste ([Miras, 2019](#)).

En el presente trabajo, se realizó un análisis de los valores de DIC dentro de una misma escala temporal (matriz del trimestre, cuatrimestre y semestre) para cada tipo de evento (El Niño y La Niña) de manera individual.

7.5.2 Salida gráfica de los modelos

Para evaluar la salida gráfica de los modelos, se construyó un mosaico para cada escala temporal. El mosaico fue realizado con el promedio de las imágenes correspondientes a las fechas utilizadas en la base de datos. Se aplicó el promedio ya que el modelo rescata dichos valores para cada celda de la grilla. Posteriormente, con los mosaicos se realizaron clasificaciones no supervisadas, proceso que genera clases espectrales de forma automática, sin intervención del usuario (Tutorial ArcGis).

Esta clasificación se efectuó mediante la función Clusterer, la cual emplea el algoritmo basado en la distancia euclidiana (k-Means), un método de aprendizaje automático que asigna automáticamente la imagen a un número predefinido de clases espectrales. Para los eventos de El Niño se definieron 4 clases, mientras que para el evento de La Niña se consideraron 5 clases. En ambos eventos, la clasificación se realizó a la banda correspondiente al rojo del espectro visible.

Una vez obtenida la clasificación no supervisada se exportó la imagen resultante y en el programa Qgis se poligonizó, transformándose así de formato raster a vectorial. Del shapefile resultante se seleccionó la clase correspondiente al área del frente de turbidez secundario (polígono verde en la figura 7) y se transformó a líneas para así definir el límite oeste como el frente de turbidez principal y el límite este como el frente de turbidez secundario, tal como se ilustra en la [figura 10](#).

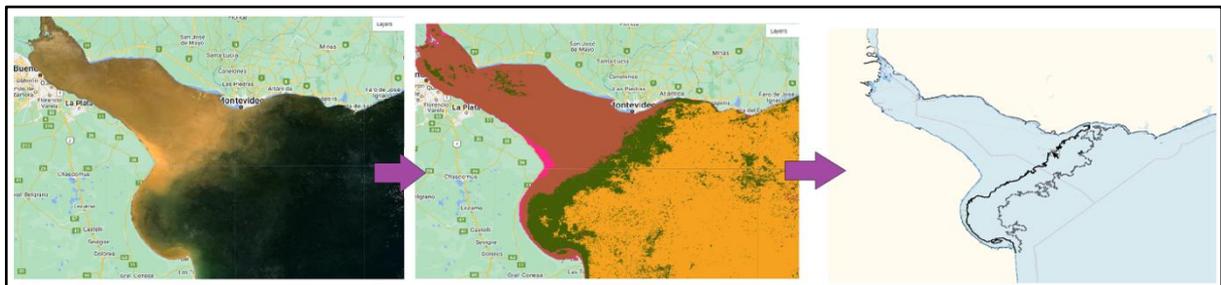


Figura 10: Procesamiento gráfico para la generación de líneas del frente de turbidez (principal y secundario) del Río de la Plata. En la imagen (a) se visualiza el mosaico. En (b) se visualiza el resultado de la clasificación no supervisada y en (c) se representa el resultado de la extracción de las líneas de la clase que se observa en verde en la figura b) Fuente: Elaboración propia.

8. Resultados

8.1 Análisis de datos

8.1.1 Exploración de datos

La salida de la matriz de correlación mostró que la dirección del viento en Montevideo y Colonia son variables altamente correlacionadas. Lo mismo ocurre con la velocidad del viento en Montevideo y Colonia. Por lo tanto, se optó por seleccionar únicamente las variables dirección de viento en Montevideo y velocidad de viento de Montevideo, dado que es en este lugar donde se registra la mayor variabilidad espacial en el frente de turbidez. En cuanto a la marea, fue establecida una alta correlación de esta variable en Colonia y Montevideo, por tanto, se utilizaron los datos de la marea medida en Montevideo, siguiendo el mismo criterio utilizado anteriormente.

Tabla 4: Matriz de correlación entre las variables físicas (explicativas). En color verde se muestran las variables correlacionadas a partir de 0.5. Correlación negativa entre variables es indicada con signo (-) a partir de -0.5.

	Dirección del viento Montevideo	Velocidad del viento Montevideo	Caudal	Marea Montevideo	Dirección del viento Colonia	Velocidad del viento Colonia	Marea Colonia
Dirección del viento Montevideo	1	-0,11	-0,04	0,21	0,83	0,03	-0,22
Velocidad del viento Montevideo	-0,11	1	0,12	-0,01	-0,13	0,77	0,11
Caudal	-0,04	0,12	1	0,08	0,01	0,10	-0,01
Marea Montevideo	0,21	-0,01	0,08	1	0,13	-0,01	-0,50
Dirección del viento Colonia	0,83	-0,13	0,01	0,13	1	-0,01	-0,17
Velocidad del viento Colonia	0,03	0,77	0,09	-0,01	-0,01	1	0,11
Marea Colonia	-0,22	0,11	-0,01	-0,50	-0,17	0,11	1

8.2 Modelización: efecto de la variabilidad interanual con forzantes ambientales.

A continuación, son presentados los resultados de los modelos generados en tres escalas temporales (3, 4 y 6 meses) para los eventos El Niño y La Niña.

Tabla 5: Resultados de valores de DIC de los modelos para los eventos El Niño/ La Niña para tres escalas temporales: 3, 4 y 6 meses. En verde se muestra el modelo con mayor rendimiento del bloque (univariado, bivariado y trivariado) y en naranja el de menor rendimiento.

Modelos	El Niño 2015 -2016			La Niña 2011-2012		
	3 meses	4 meses	6 meses	3 meses	4 meses	6 meses
Espacial	-1690,81	-2485,24	-3506,73	-2149,15	-2281,60	-3732,65
Dirección del viento	-1790,25	-2656,20	-3680,12	-2193,96	-2290,42	-3793,41
Velocidad del viento	-1781,30	-2569,79	-3652,35	-2155,59	-2301,10	-3757,51
Caudal	-1815,70	-2658,38	-3709,09	-2189,09	-2292,62	-3788,62
Marea	-1737,51	-2561,22	-3556,71	-2147,25	-2279,93	-3730,99
Velocidad del viento y caudal	-1815,77	-2658,10	-3709,85	-2189,19	-2292,38	-3788,65
Dirección del viento y caudal	-1815,72	-2665,80	-3709,02	-2189,69	-2292,63	-3788,96
Marea y caudal	-1815,07	-2658,11	-3709,24	-2189,25	-2293,05	-3789,05
Velocidad del viento y marea	-1763,76	-2610,49	-3641,91	-2156,58	-2299,65	-3755,34
Dirección del viento y marea	-1789,61	-2654,77	-3692,57	-2194,38	-2289,17	-3795,21
Dirección y velocidad del viento	-1789,70	-2665,58	-3694,48	-2191,19	-2298,59	-3793,65
Caudal, dirección del viento y marea	-1815,43	-2665,20	-3710,43	-2189,18	-2294,32	-3788,94
Marea, dirección y velocidad del viento	-1790,77	-2665,07	-3703,17	-2191,96	-2296,03	-3796,22
Caudal, dirección y velocidad del viento	-1816,62	-2671,81	-3709,15	-2189,31	2292,35	-3788,56
Caudal, dirección del viento y marea	-1816,31	-2659,85	-3708,84	-2180,74	-2293,39	-3789,54
Caudal, marea dirección y velocidad del viento	-1816,07	-2670,24	-3710,16	-2189,70	-2293,40	-3789,54

8.2.1. Escala temporal: 3 meses

El Niño

El modelo espacial presentó el menor rendimiento entre todos los modelos considerados para el evento El Niño. En modelos univariados, el modelo que presentó mayor rendimiento fue el modelo que incluyó al caudal y el de menor rendimiento el que incluyó la marea ([Figura 11](#)). Estos resultados se ven reflejados en la salida gráfica donde el modelo de la variable caudal presenta un frente con una sinuosidad que se acerca más a la realidad mientras que el modelo de marea presenta una zona horizontal que no refleja la realidad del frente. Por otro lado, se puede observar que el modelo de caudal presenta mayor intensidad en el color del estuario, indicando mayores valores de reflectancia, acentuado en la zona de Punta Piedras.

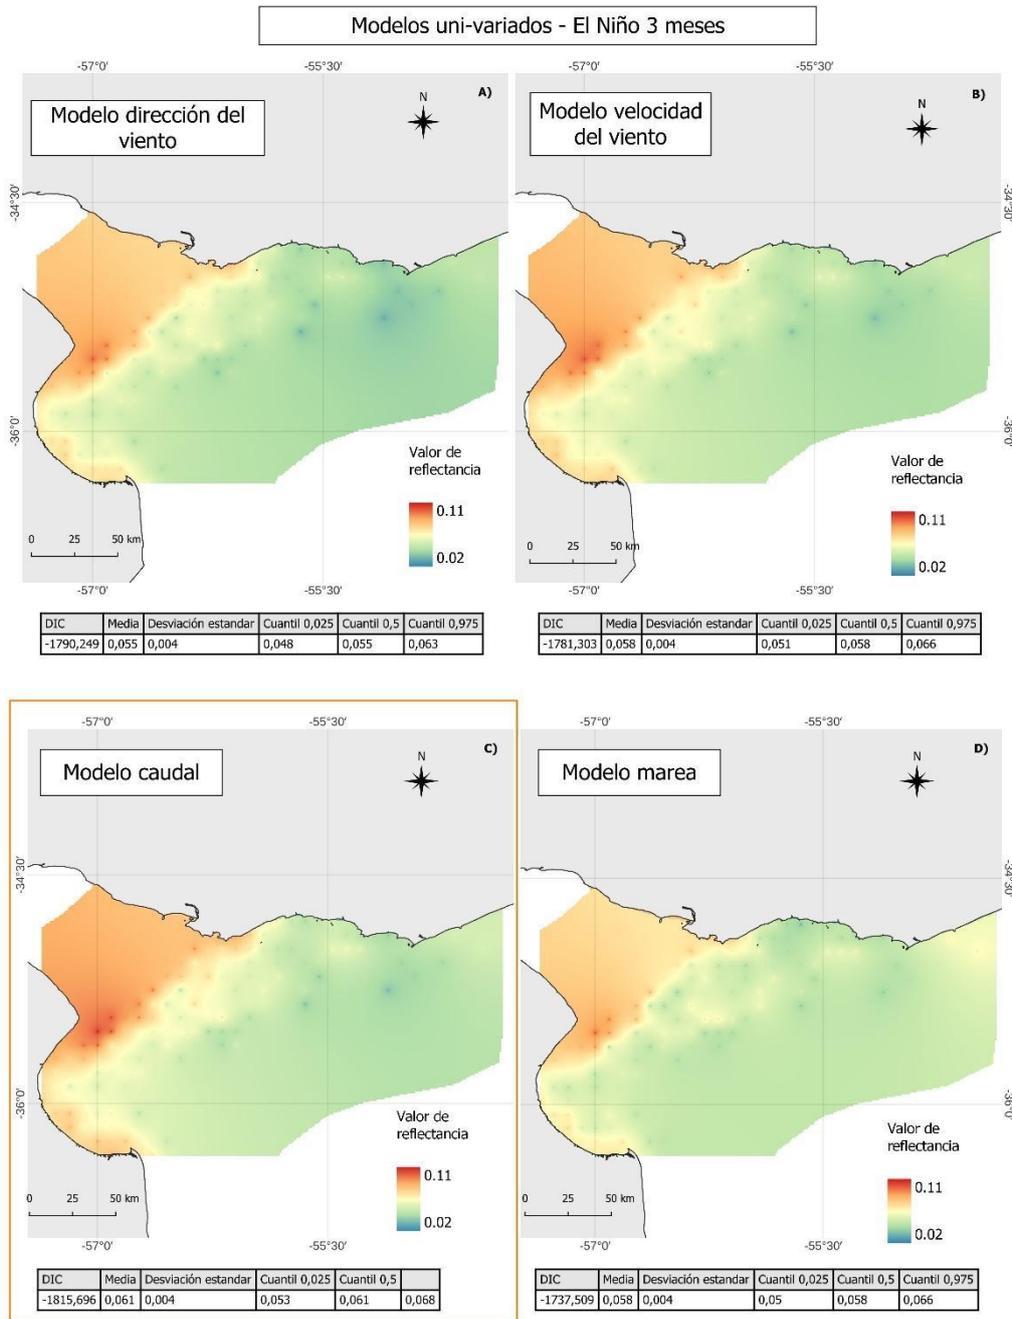


Figura 11: Evento El Niño, modelos uni-variados. Salida gráfica en escala de 3 meses. a) Modelo con la variable dirección del viento. b) Modelo que incluye velocidad de viento c) Modelo que incluye caudal. d) Modelo que incluye marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En modelos bivariados, la combinación de las variables caudal y velocidad del viento generó el modelo de mayor rendimiento ([Figura 12](#)). Los modelos que incorporan la variable caudal presentan el mismo patrón espacial ([Figura 12](#)) manteniendo los patrones observados en el modelo univariado de caudal y velocidad del viento ([Figura 11](#)).

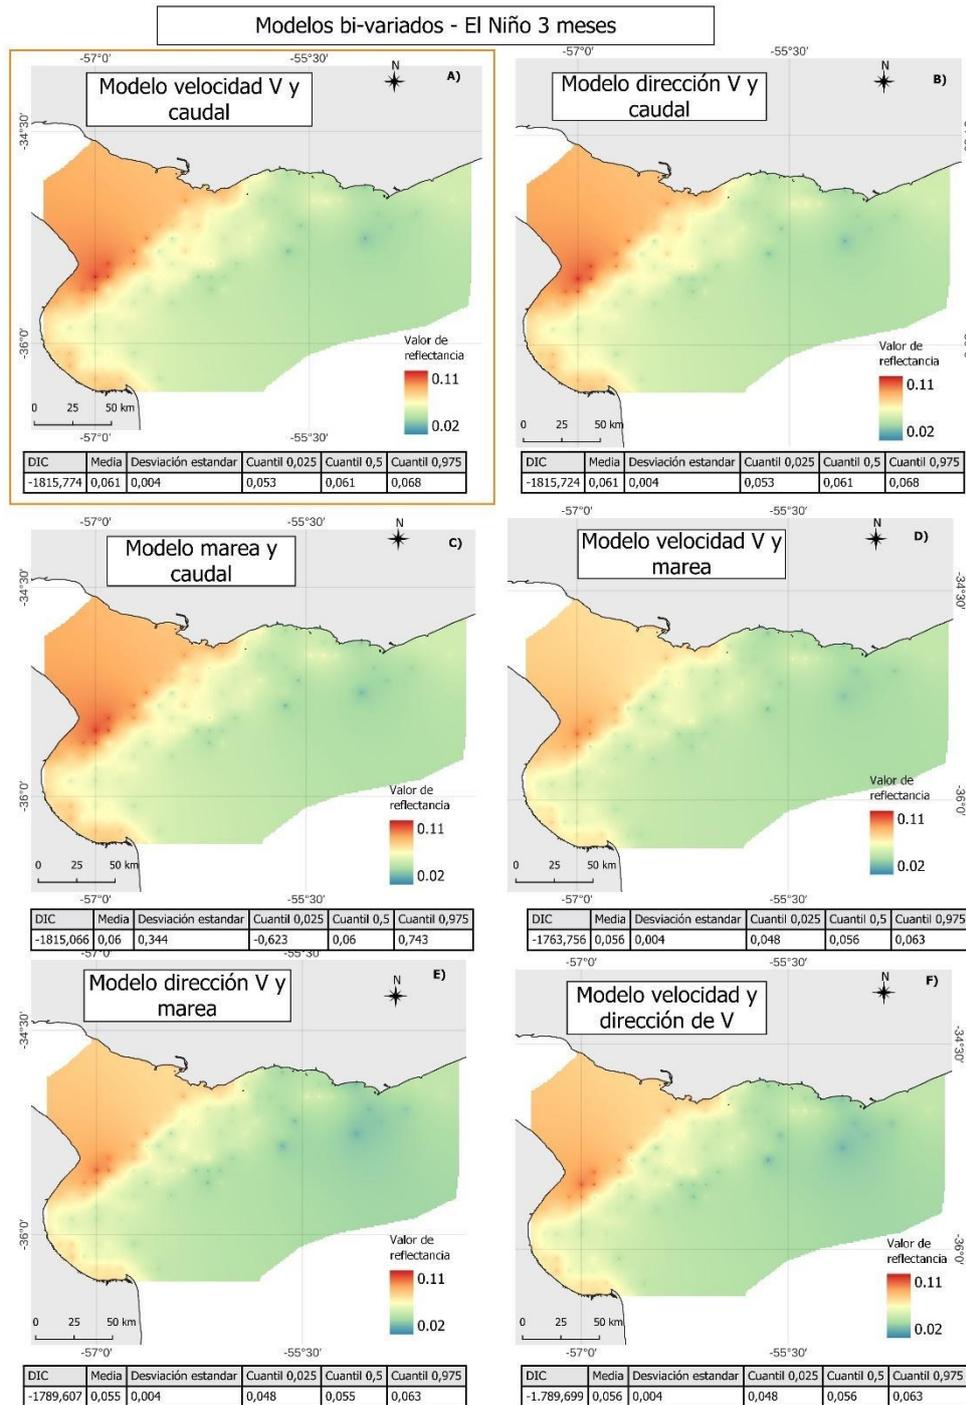


Figura 12: Evento El Niño, modelos bi-variados. Salida gráfica en escala temporal de 3 meses. A) Modelo combinando dirección del viento y caudal. B) Modelo combinando velocidad de viento y caudal C) Modelo combinando marea y caudal. D) Modelo combinando velocidad de viento y marea. E) Modelo combinando dirección de viento y marea F) Modelo combinando velocidad y dirección de viento Debajo de cada salida gráfica se encuentran el valor del Criterio de información de desviación(DIC) de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En tri-variados, el modelo con mayor rendimiento incorporó a las variables caudal, dirección y velocidad de viento. La salida gráfica de este modelo sigue el patrón espacial de los modelos de caudal y velocidad de viento. ([Figura 13](#)).

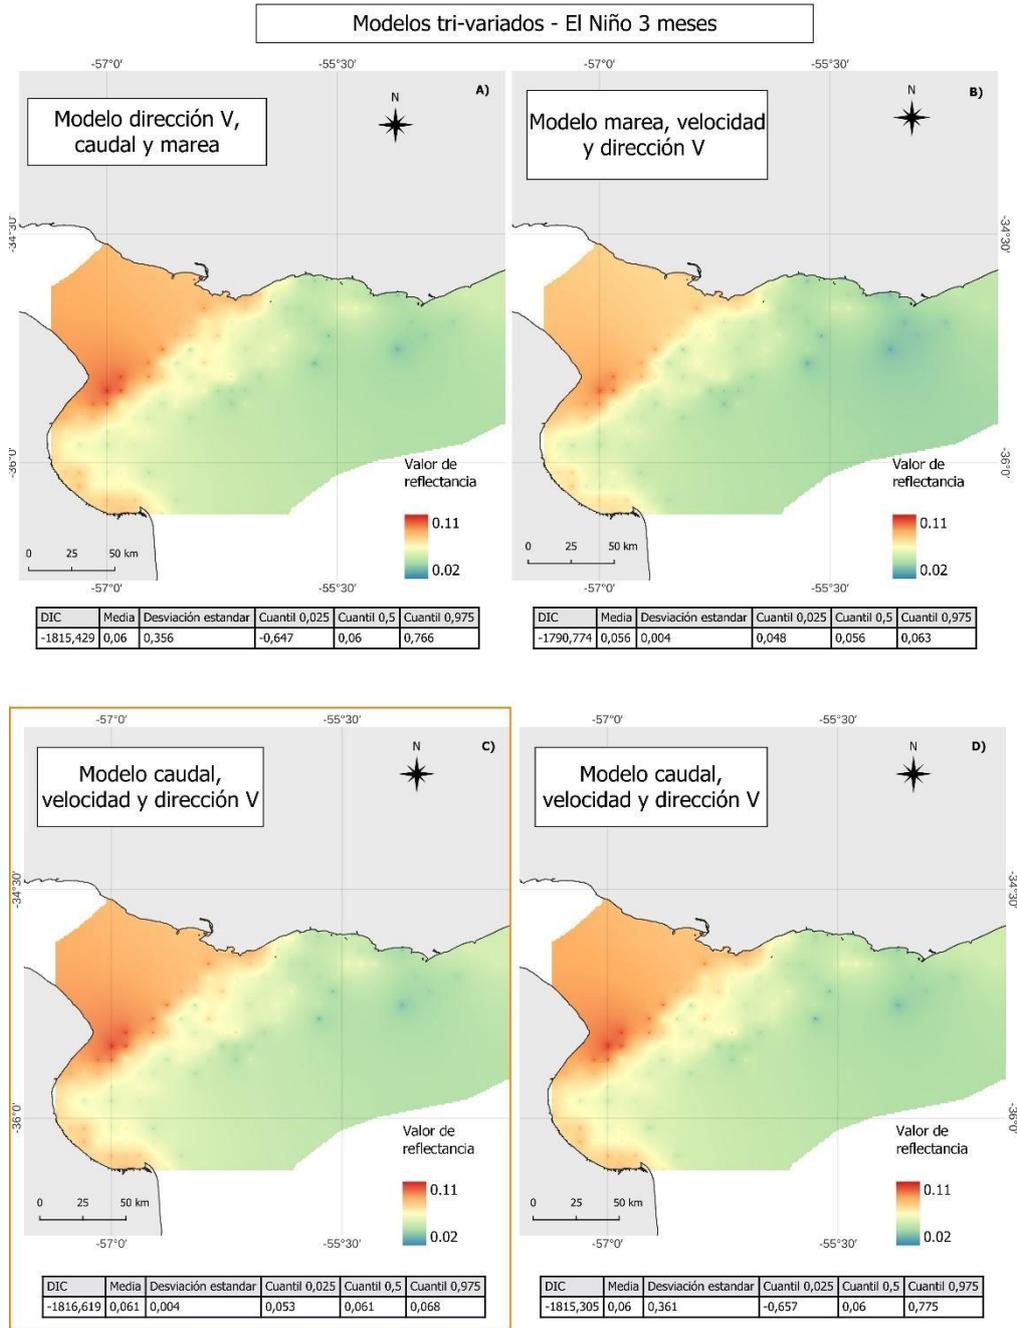


Figura 13: Salida gráfica de los modelos tri-variados en evento El Niño escala temporal 3 meses. A) Modelo con las variables dirección del viento, caudal y mareal. B) Modelo que combina marea, velocidad y dirección de viento. C) Modelo que combina caudal, velocidad y dirección de viento. D) Modelo que combina las variables caudales, velocidad y dirección de viento. Debajo de cada salida gráfica se muestran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En tetravariados (incluye a todas las variables explicativas), el rendimiento del modelo de 3 meses ([Figura 14](#)) obtuvo un valor de DIC similar al que obtuvo el modelo trivariado ([Tabla 5](#)). La salida gráfica presenta los mismos patrones espaciales observados al modelo trivariado mencionado anteriormente.

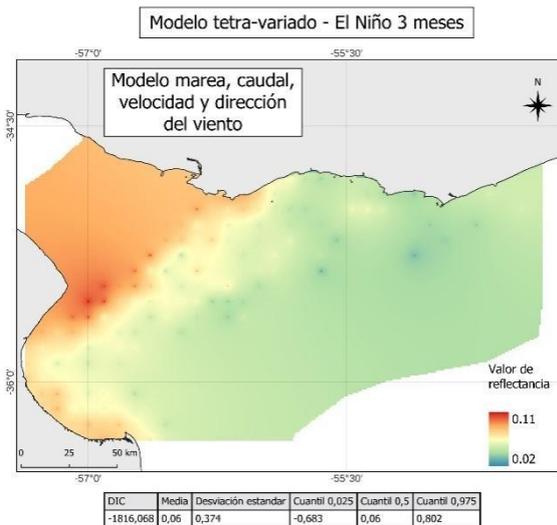


Figura 14: Modelos tetra - variados en evento El Niño para escala temporal 3 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC de cada modelo y su intervalo de confianza.

La Niña

Los modelos con mayor rendimiento fueron aquellos que incorporan la variable dirección del viento. Por el contrario, los modelos con menor rendimiento fueron los que incorporaron la variable marea ([Tabla 5](#)).

En univariados, el modelo de mayor rendimiento incluyó dirección del viento y en cambio, el modelo con menor rendimiento incluyó a la marea, esto se ve reflejado en las salidas gráficas cuando se comparan ambas se observa que en la salida gráfica del modelo de dirección de viento hay una mayor definición de la turbidez en la costa uruguaya y valores más altos sobre Punta Piedras. ([Figura 15](#)).

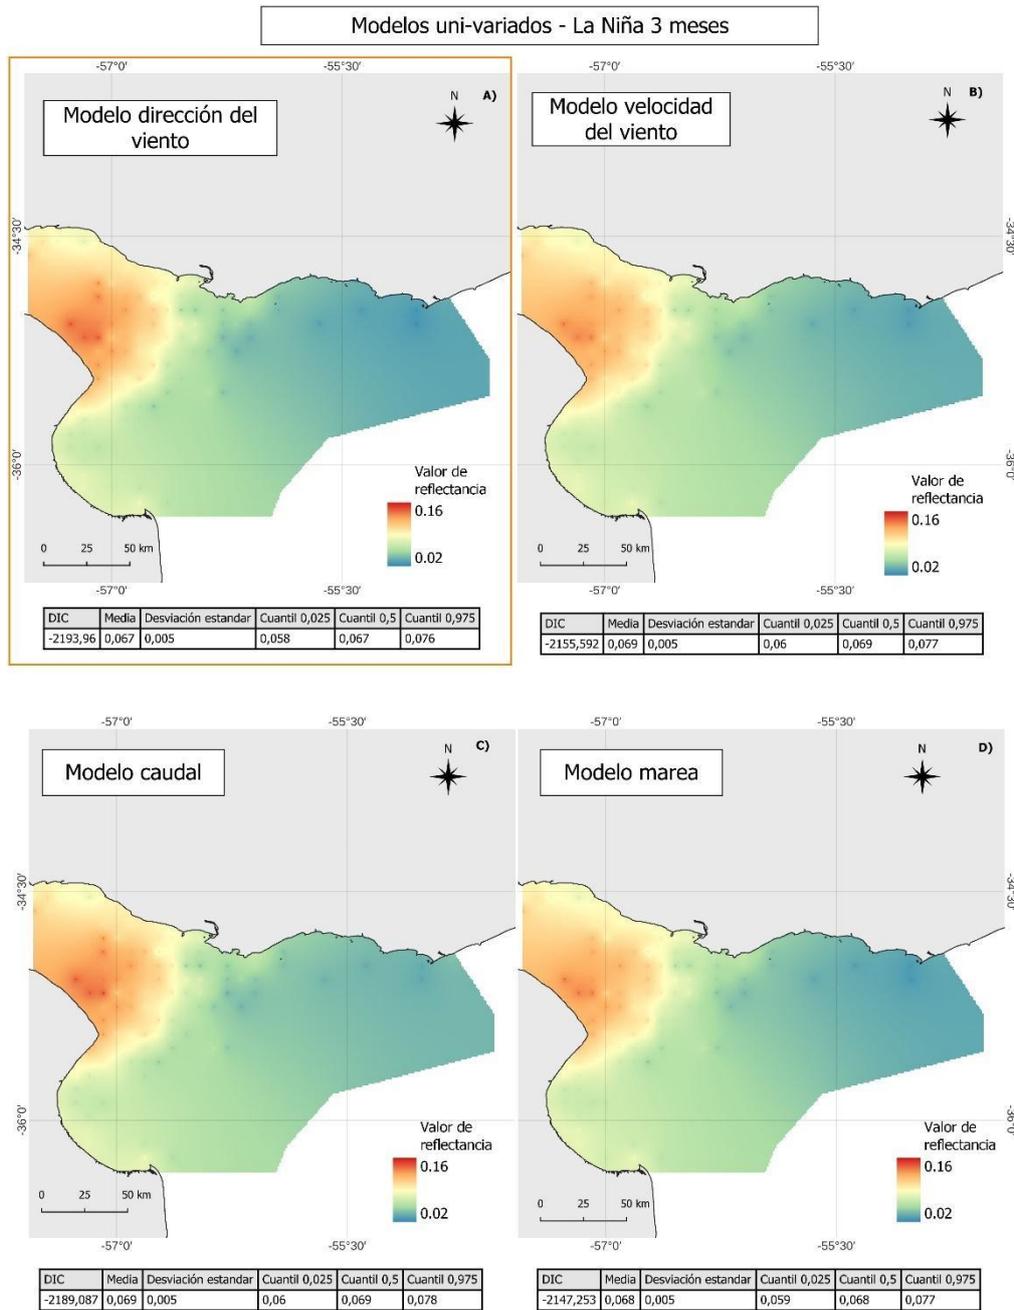


Figura 15: Salida gráfica de los modelos univariados en evento La Niña 3 meses. a) Modelo con la variable dirección del viento. b) Modelo con la variable velocidad de viento c) Modelo con la variable caudal. d) Modelo con la variable marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En bivariados, el modelo con mayor rendimiento combinó dirección del viento y marea. En contraste, el de menor rendimiento fue el modelo que combinó velocidad de viento y marea. En la salida gráfica de esta combinación de variables se ve una similitud con la salida gráfica del modelo univariado de dirección de viento y en comparación con los otros modelos bivariados se observa una mayor definición de la zona de turbidez ([Figura 15](#)).

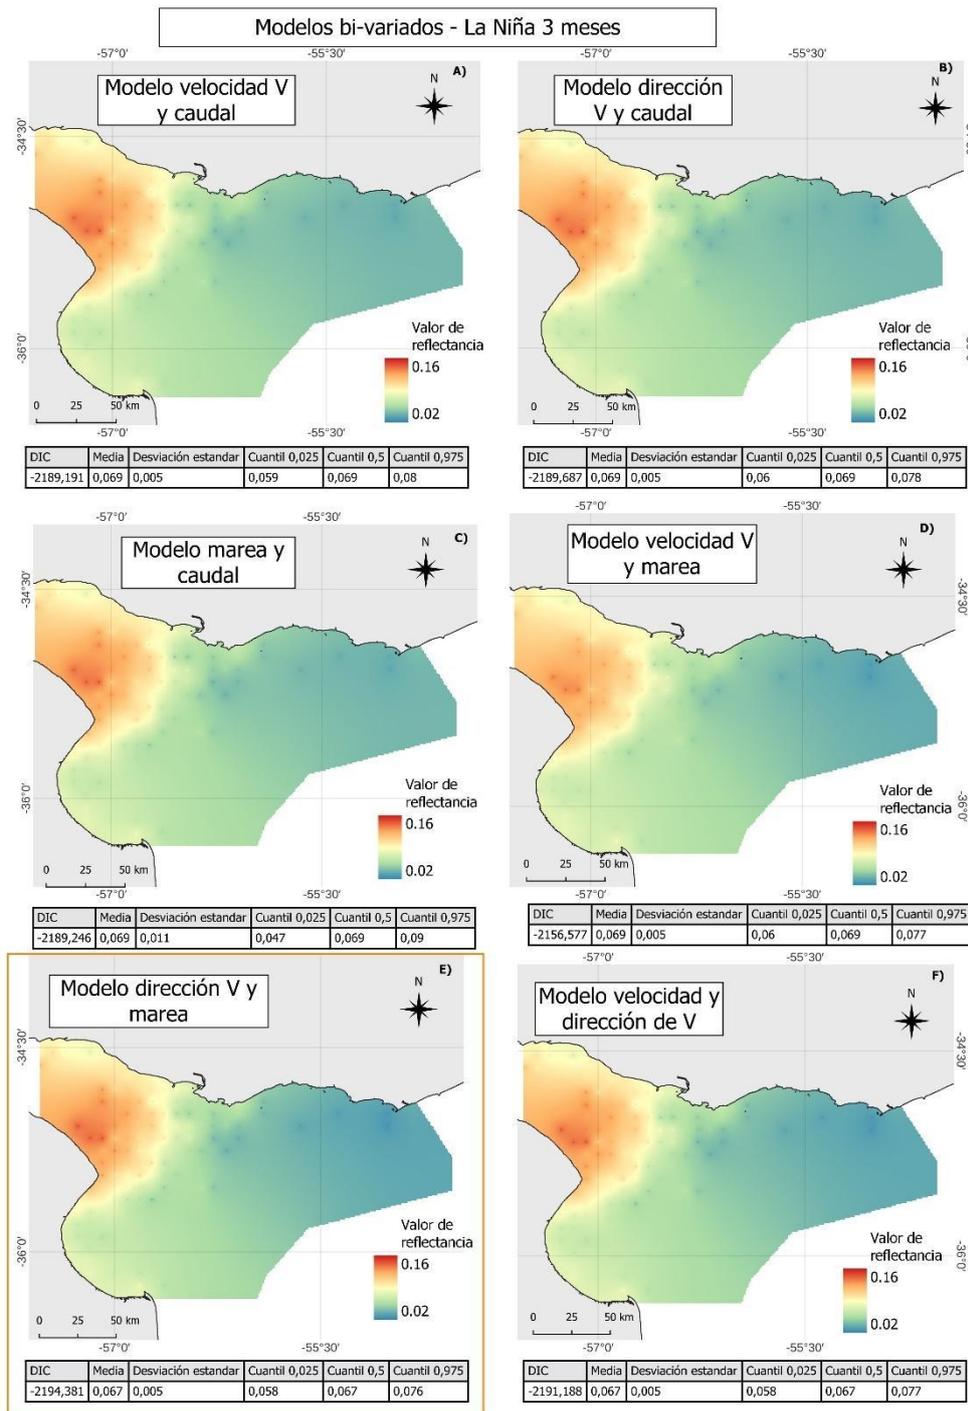


Figura 15: Salida gráfica de los modelos bivariados en evento La Niña escala temporal 3 meses. A) Modelo que combina dirección del viento y caudal. B) Modelo que combina velocidad de viento y caudal. C) Modelo con las variables marea y caudal. D) Modelo que incluye velocidad de viento y marea. E) Modelo que combina dirección de viento y marea. F) Modelo que combina las variables velocidad y dirección de viento. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En trivariados, el modelo de mayor rendimiento contempló las variables marea, velocidad y dirección de viento. En lo opuesto, el modelo con menor rendimiento resultante combinó caudal, dirección del viento y marea. Al combinar tres variables las salidas gráficas no presentan diferencias significativas ([Figura 16](#)).

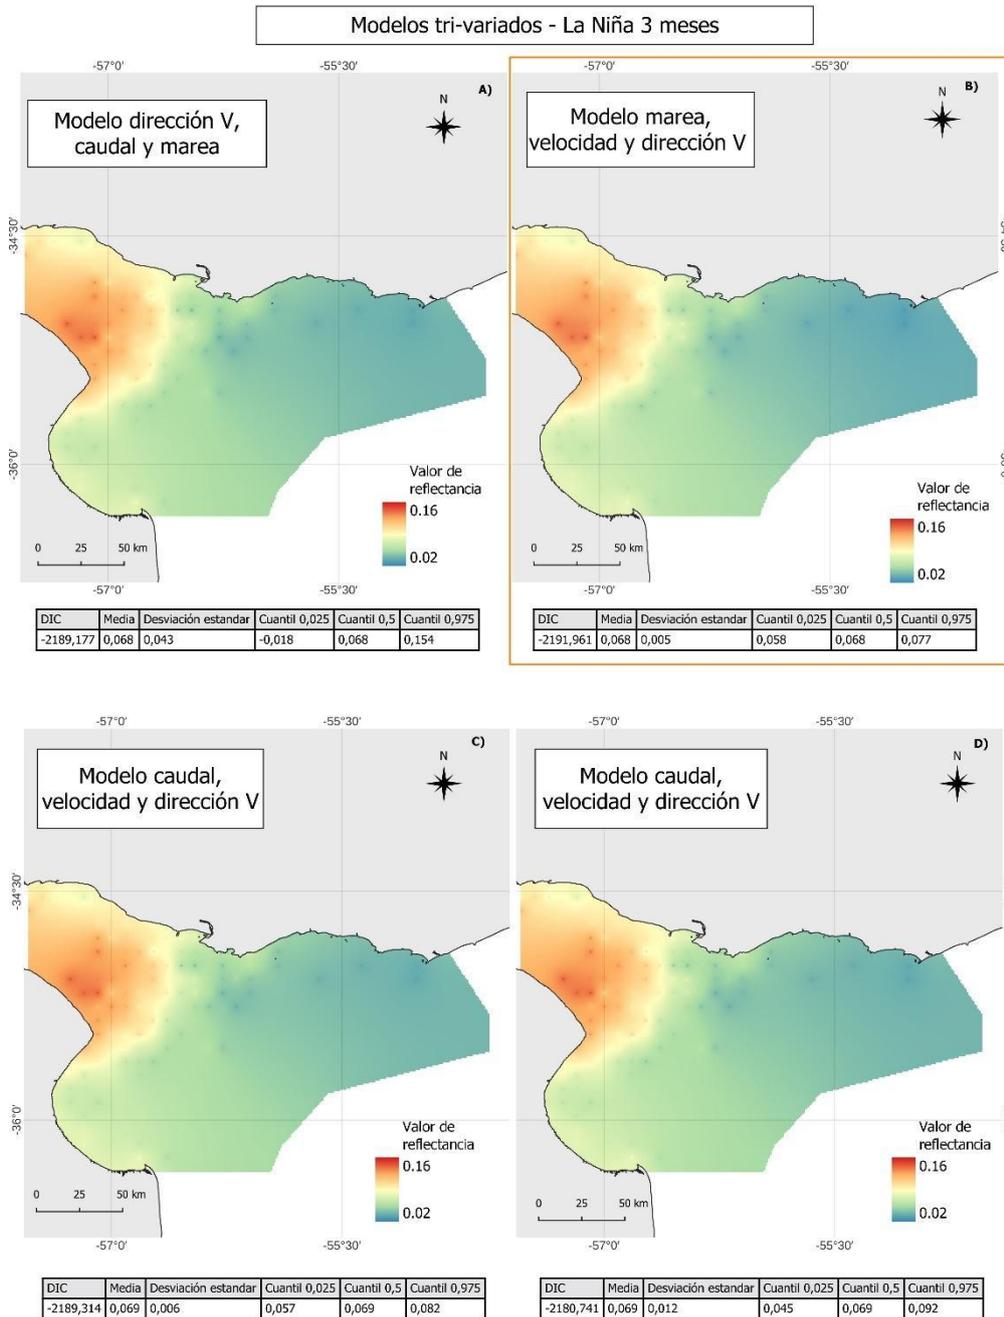


Figura 16: Salida gráfica de los modelos tri-variados en evento La Niña escala temporal 3 meses. A) Modelo con las variables dirección del viento, cauda y mareal. B) Modelo que combina marea, velocidad y dirección de viento. C) Modelo que combina caudal, velocidad y dirección de viento. D) Modelo que combina las variables caudal, velocidad y dirección de viento. Debajo de cada salida gráfica se muestran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

El modelo tetravariado para La Niña mostró un rendimiento similar al modelo trivariado. La salida gráfica no muestra diferencias con las obtenidas en los modelos tri variados ([Figura 17](#)).

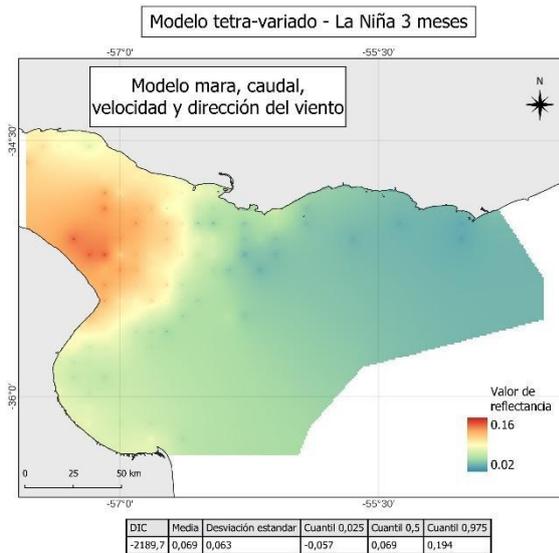


Figura 17: Modelos tetra- variados en evento La Niña para escala temporal 3 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC de cada modelo y su intervalo de confianza.

8.2.2. Escala temporal: 4 meses

El Niño

Los modelos univariados de 4 meses, con mayor y menor rendimiento, coinciden con la escala temporal de 3 meses. Las salidas gráficas de los cuatro modelos univariados presentan una forma del frente de turbidez sinuosa a diferencia de los modelos univariados de la escala temporal de 3 meses que el único que presentaba estos patrones era el modelo de la variable caudal. En las salidas gráficas de esta escala temporal (4 meses) se puede observar una ligera diferencia en la zona sur que deja más definido al frente de turbidez ([Figura 18](#)).

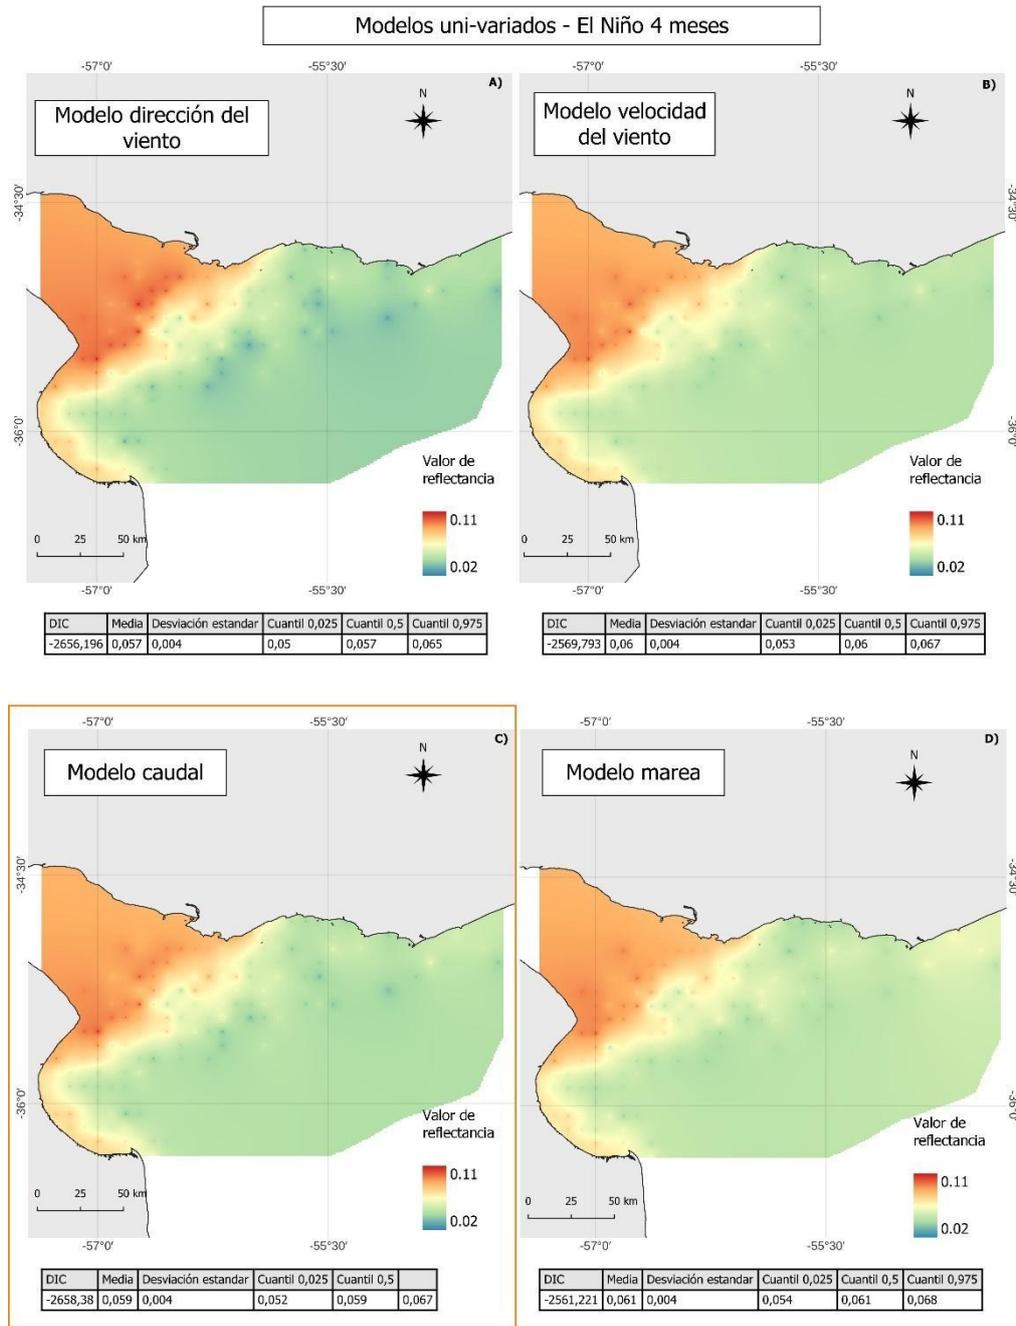


Figura 18: Salida gráfica de los modelos univariados en evento El Niño escala temporal 4 meses. a) Modelo que incluye dirección del viento. b) Modelo que incluye velocidad de viento c) Modelo con la variable caudal. d) Modelo que incluye variable marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento

En los modelos bivariados el modelo con mayor rendimiento incorporó las dos dimensiones del viento, dirección y velocidad. La salida gráfica del mismo podemos observar que la zona de turbidez se encuentra con valores más altos que otros modelos quedando ésta más diferenciada ([Figura 19](#)).

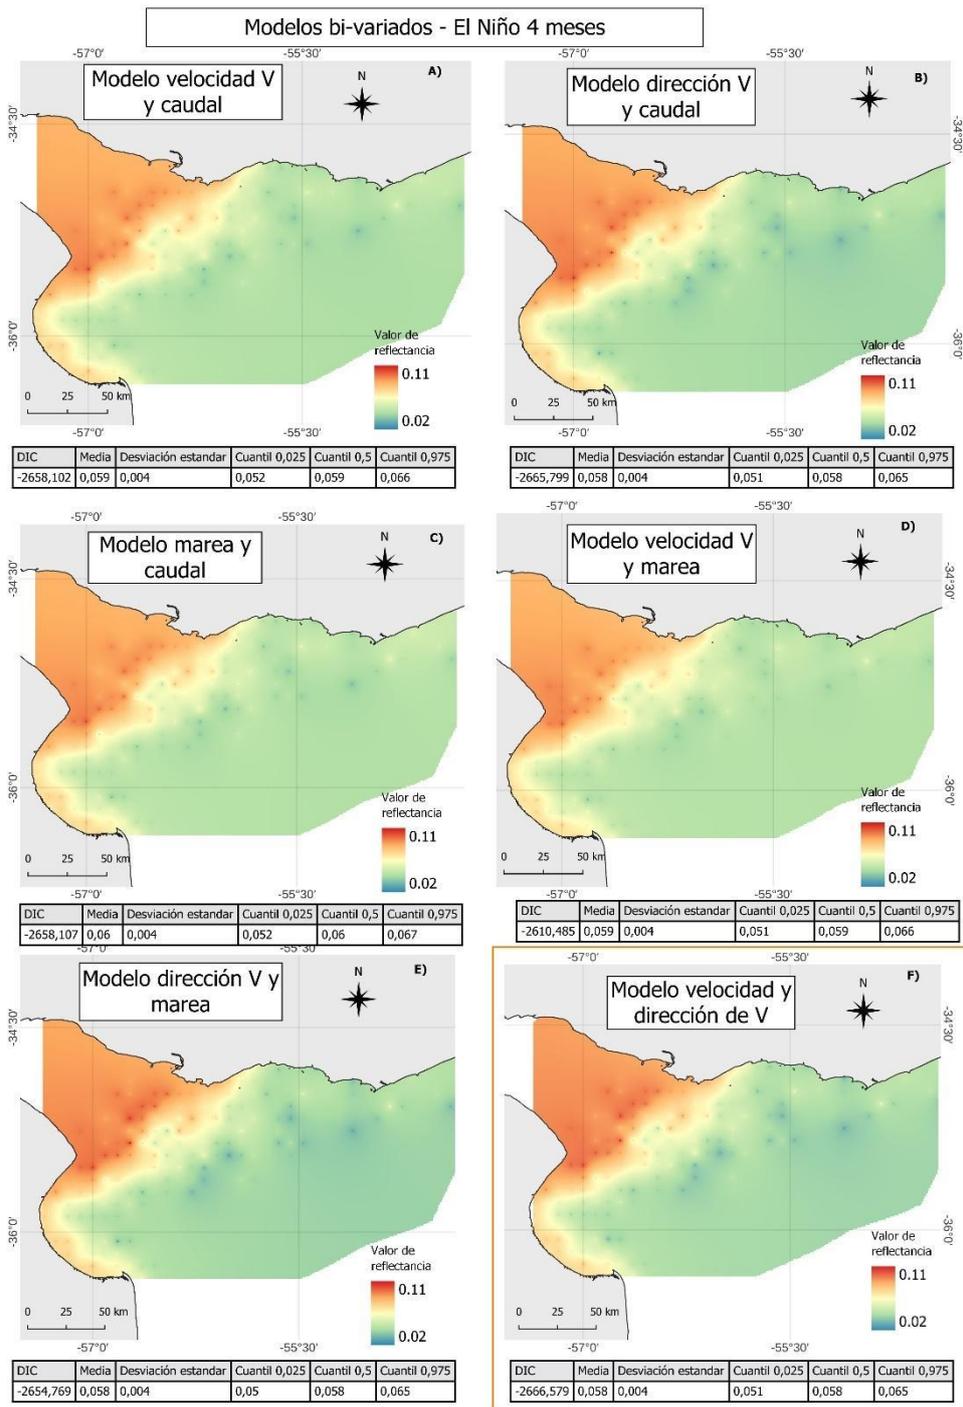


Figura 19: Salida gráfica de los modelos bivariados en evento El Niño escala temporal 4 meses. A) Modelo con que combina dirección del viento y caudal. B) Modelo que combina velocidad de viento y caudal C) Modelo con la variables marea y caudal. D) Modelo con la variables velocidad de viento y marea. E) Modelo que combina dirección de viento y marea F) Modelo que combina velocidad y dirección de viento. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En los modelos trivariados el modelo de mayor rendimiento coincide con la escala temporal de 3 meses siendo el que incorpora las dos dimensiones del viento y el caudal. Por el contrario, el modelo de menor rendimiento incorporó las variables caudal, velocidad del viento y marea. Las salidas gráficas de los modelos tri variados no presentan diferencias significativas ([Figura 20](#)).

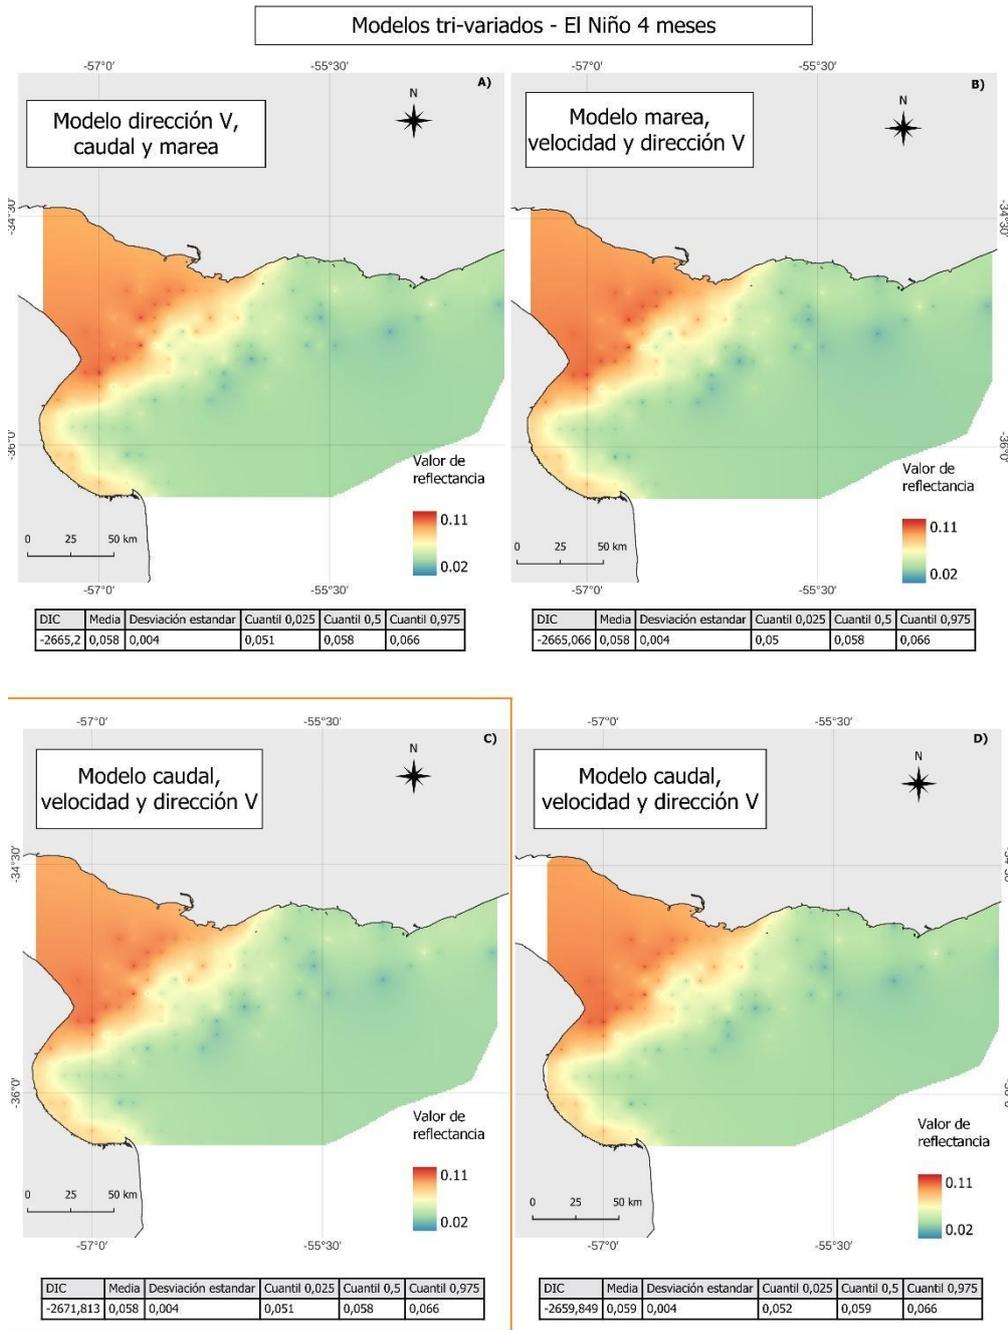


Figura 20: Salida gráfica de los modelos trivariados en evento El Niño escala temporal 4 meses. A) Modelo con las variables dirección del viento, caudal y mareal. B) Modelo que combina marea, velocidad y dirección de viento. C) Modelo que combina caudal, velocidad y dirección de viento. D) Modelo que combina las variables caudal, velocidad y dirección de viento. Debajo de cada salida gráfica se muestran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

El modelo tetra variado para El Niño presentó una diferencia menor respecto al modelo trivariado de mayor rendimiento y la salida gráfica no presenta diferencias significativas ([Figura 21](#)).

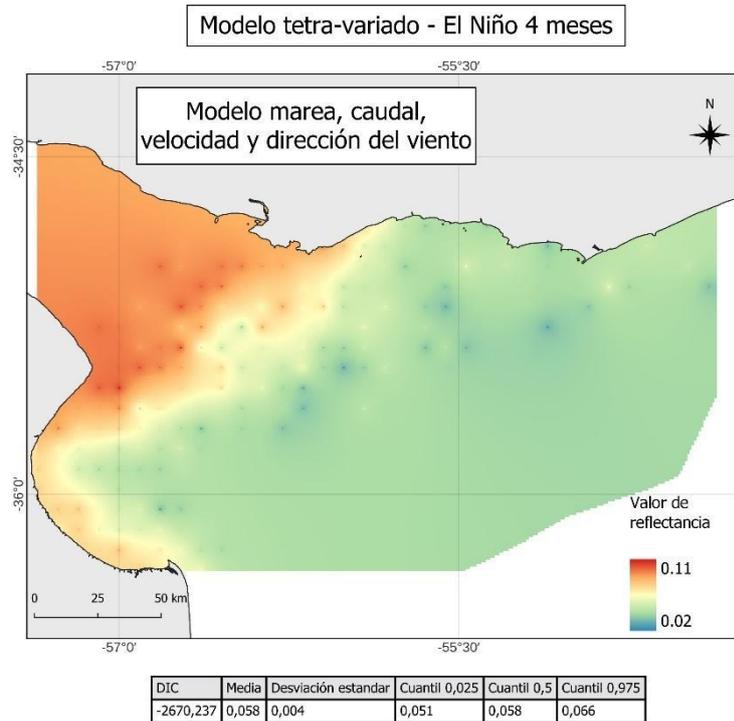


Figura 21: Modelos tetra - variado en evento El Niño para escala temporal 4 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC del modelo y su intervalo de confianza.

La Niña

En el evento La Niña vemos algunas diferencias. En los modelos que incorporan una sola variable el modelo con mayor rendimiento sigue estando dentro de las componentes del viento, pero en este caso corresponde a la velocidad. Si bien la salida gráfica de este modelo logra representar bien el límite del frente de turbidez se observa que la salida gráfica del modelo de caudal logra resaltar con mayor nitidez la pluma de turbidez del estuario ([Figura 22](#)).

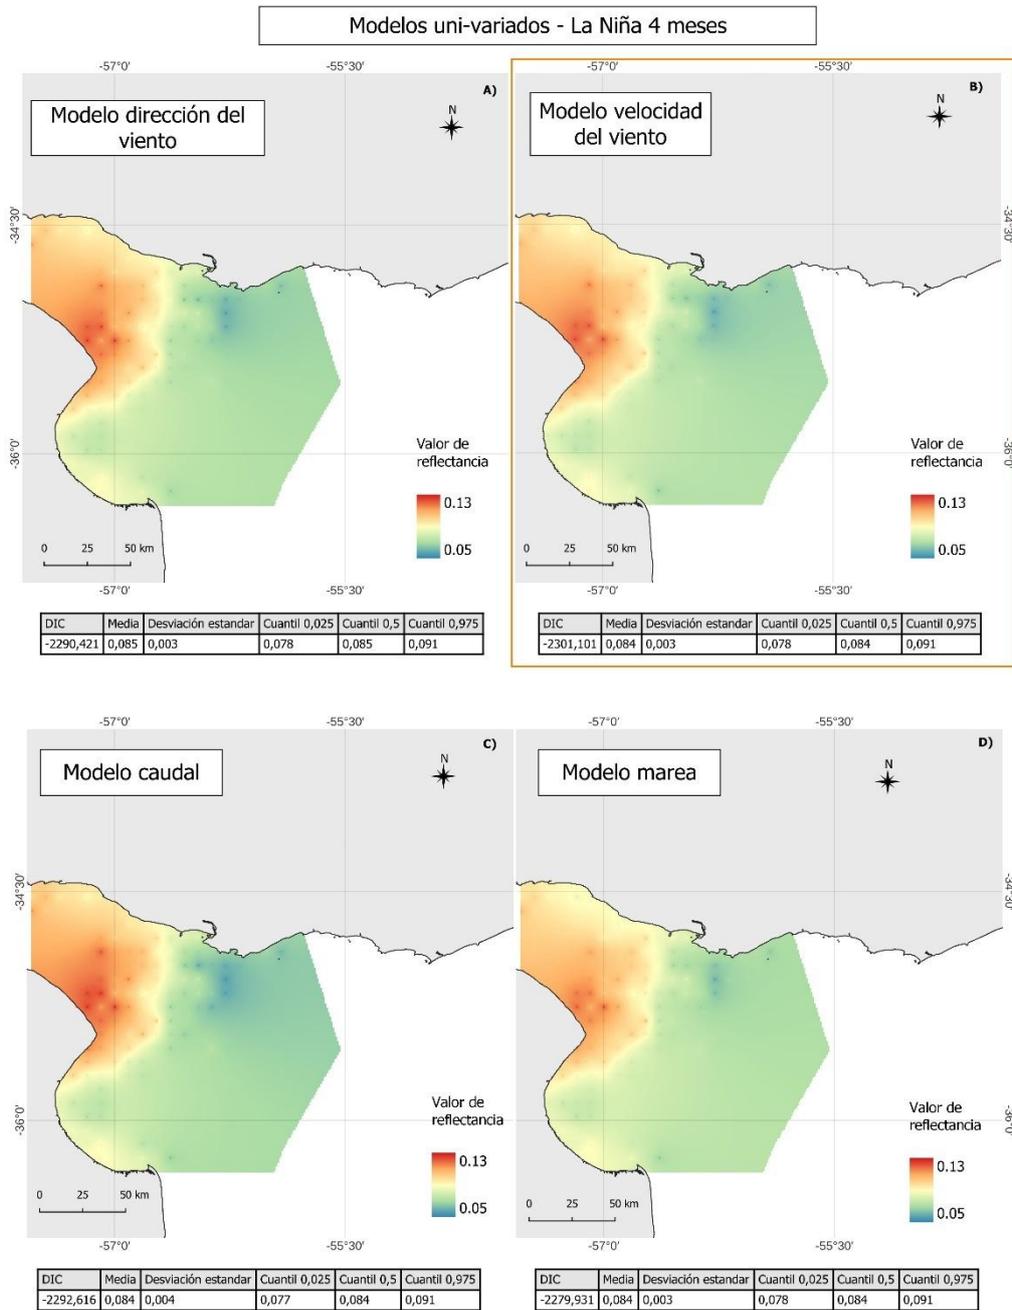


Figura 22: Salida gráfica de los modelos univariados en evento La Niña escala temporal 4 meses. a) Modelo que incluye la dirección del viento. b) Modelo que incluye a velocidad de viento c) Modelo que incluye a caudal. d) Modelo que incluye a la marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

Mientras que el modelo de menor rendimiento es el modelo de la variable marea coincidiendo con la escala temporal anterior. Cuando se modelan dos variables el modelo con mayor rendimiento es el modelo que combina velocidad y marea. En las salidas graficas se continua observando la diferencia en los valores de reflectancia que representan la turbidez en los modelos con la variable caudal ([Figura 23](#)).

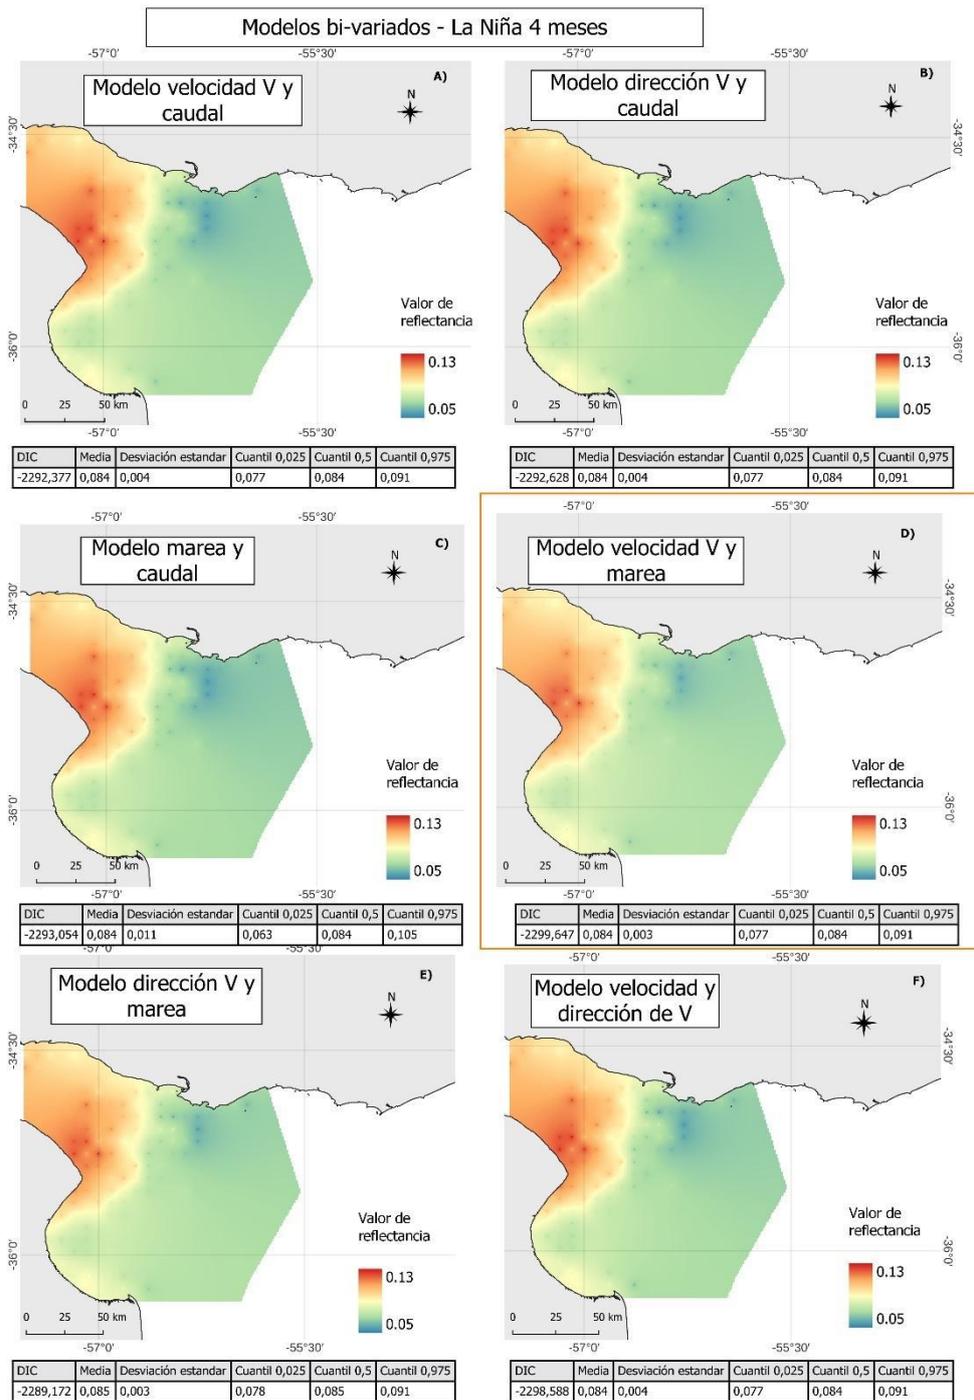


Figura 23: Salida gráfica de los modelos bivariados en evento La Niña para escala temporal 4 meses. A) Modelo que combina dirección del viento y caudal. B) Modelo que combina velocidad de viento y caudal C) Modelo con las variables marea y caudal. D) Modelo con las variables velocidad de viento y marea. E) Modelo que combina dirección de viento y marea F) Modelo que combina velocidad y dirección de viento. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

Al modelar tres variables los resultados coinciden con la escala temporal anterior siendo el modelo de marea, dirección y velocidad del viento el de mayor rendimiento y el modelo de caudal, dirección y velocidad del viento de menor rendimiento. Al combinar tres y cuatro variables las salidas gráficas comienzan a unificarse ([Figura 24](#) y [Figura 25](#)).

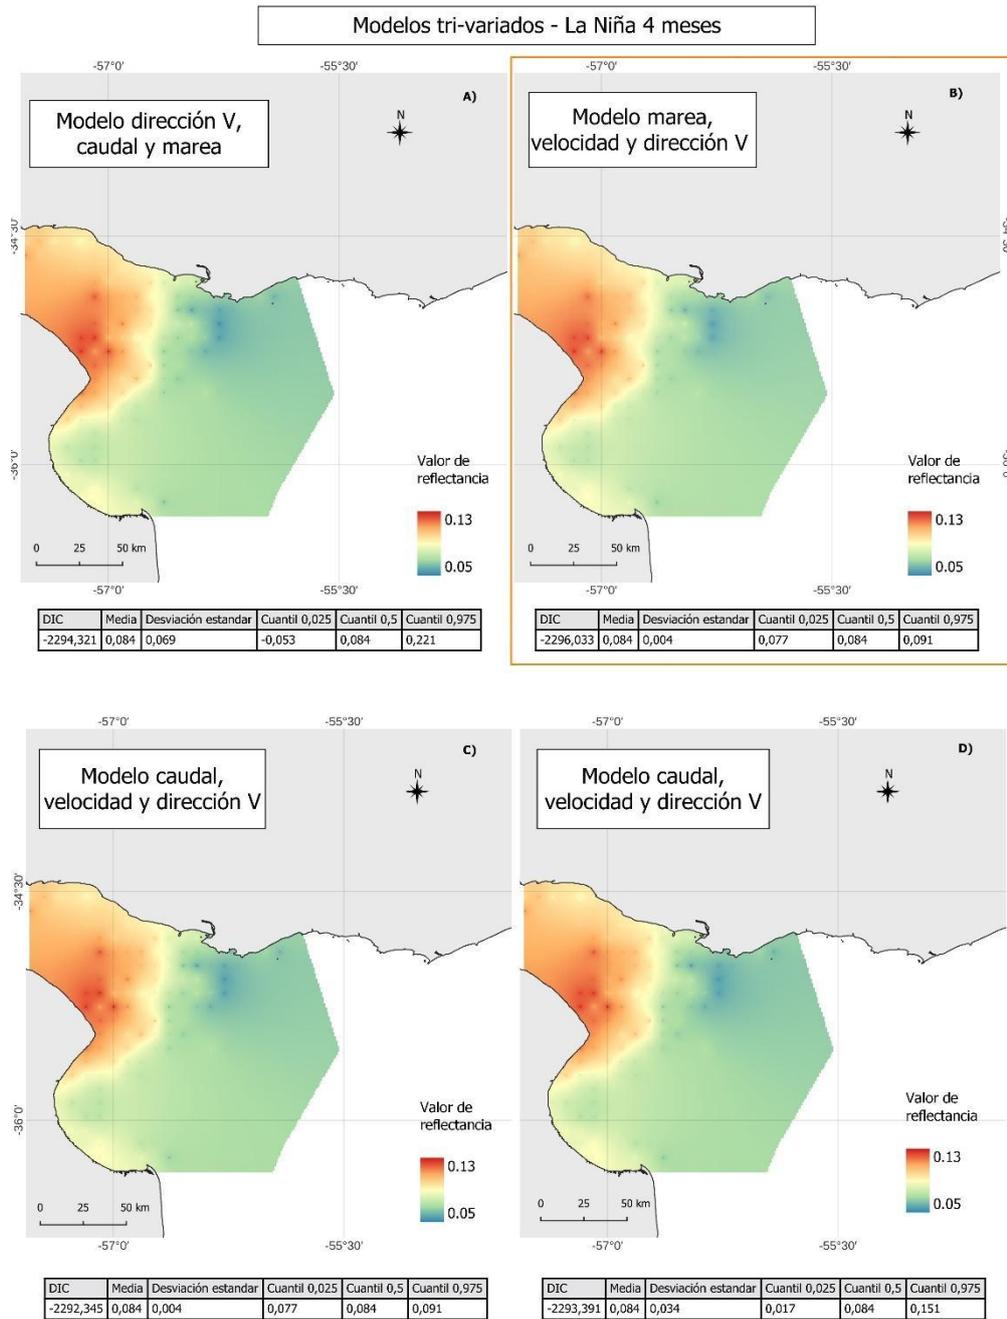


Figura 24: Salida gráfica de los modelos trivariados en evento La Niña para escala temporal de 4 meses. A) Modelo que combina dirección del viento, cauda y mareal. B) Modelo que combina marea, velocidad y dirección delviento C) Modelo que combina caudal, velocidad y dirección de viento.. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento

Al incorporar las cuatro variables al modelo ([Figura 25](#)), el resultado del DIC obtenido es similar al modelo trivariado ([Figura 24](#)).

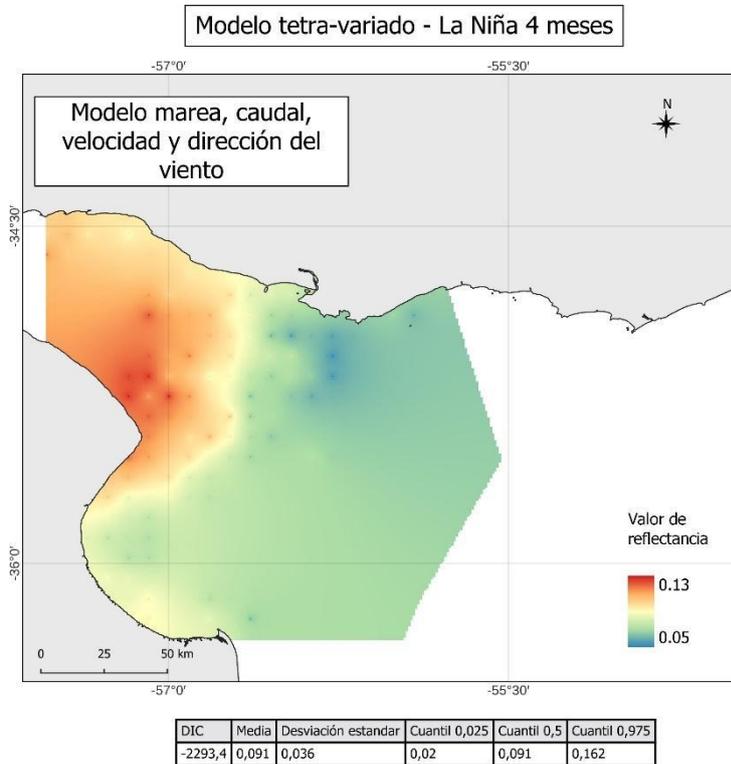


Figura 25: Modelos tetra- variados en evento La Niña para escala temporal 4 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo.

8.2.3. Escala temporal: 6 meses

El Niño

Los modelos univariados ([Figura 26](#)) y bivariados ([Figura 27](#)) para El Niño en la escala temporal de 6 meses tienen el mismo rendimiento que los modelos univariados para la escala temporal de 3 meses.

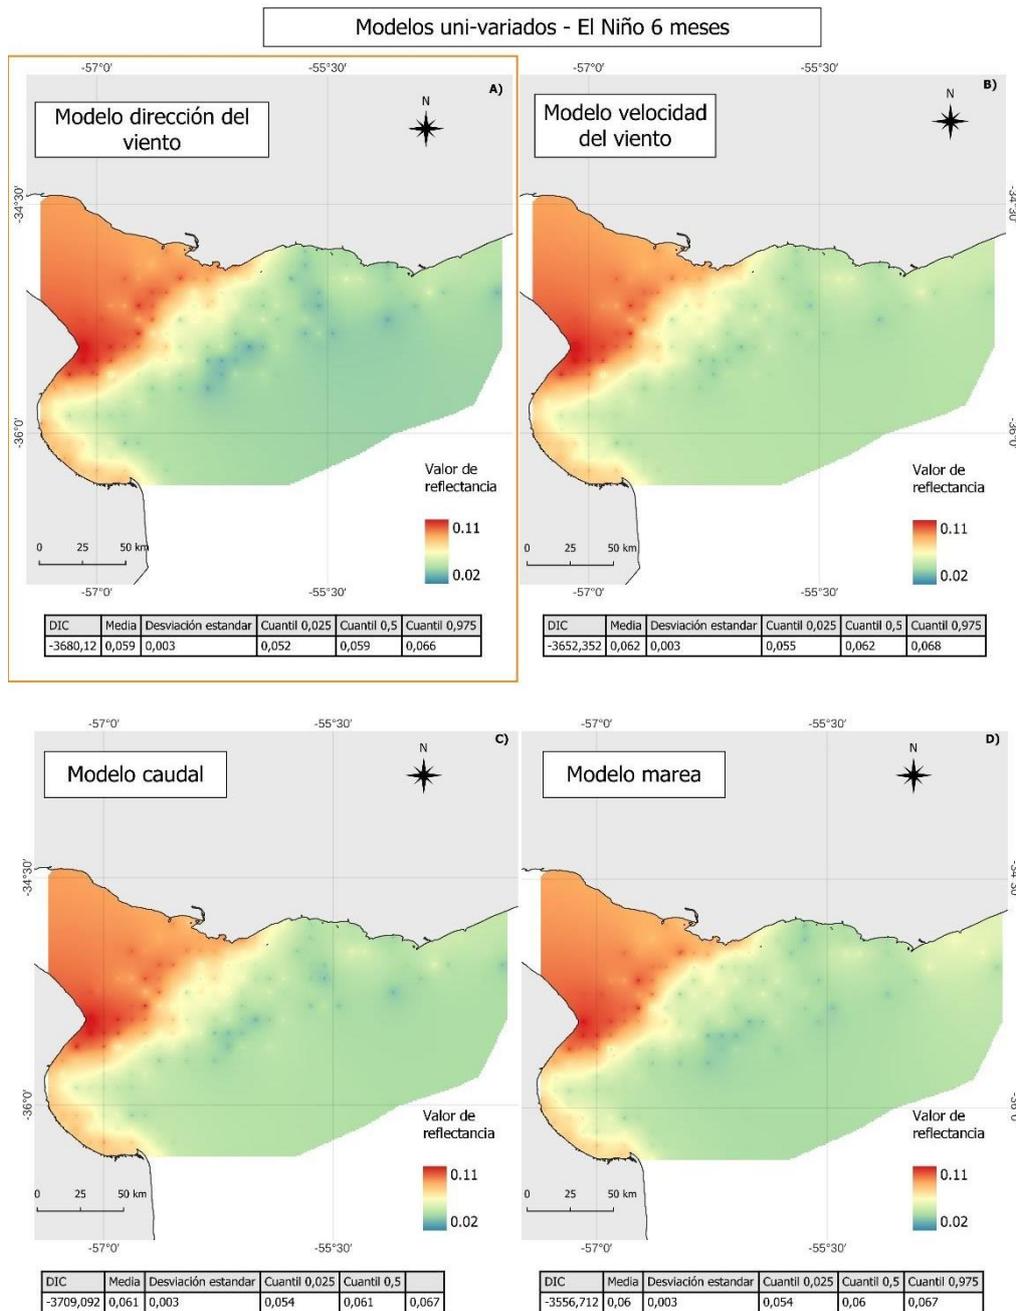


Figura 26: Salida gráfica de los modelos univariados en evento El Niño para escala temporal 6 meses. a) Modelo que incluye a dirección del viento. b) Modelo que incluye a velocidad de viento c) Modelo que incluye caudal. d) Modelo que incluye a marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En bivariados resaltan los modelos que combinan la variable caudal con otras variables tales como caudal y velocidad del viento. En las salidas gráficas de los modelos univariados se vuelve a observar el problema de tramos rectos del frente en

la zona de la Barra del Indio más acentuado en el modelo de la variable marea. Sin embargo, en la salida gráfica del modelo que combina dirección del viento y marea este problema queda resuelto.

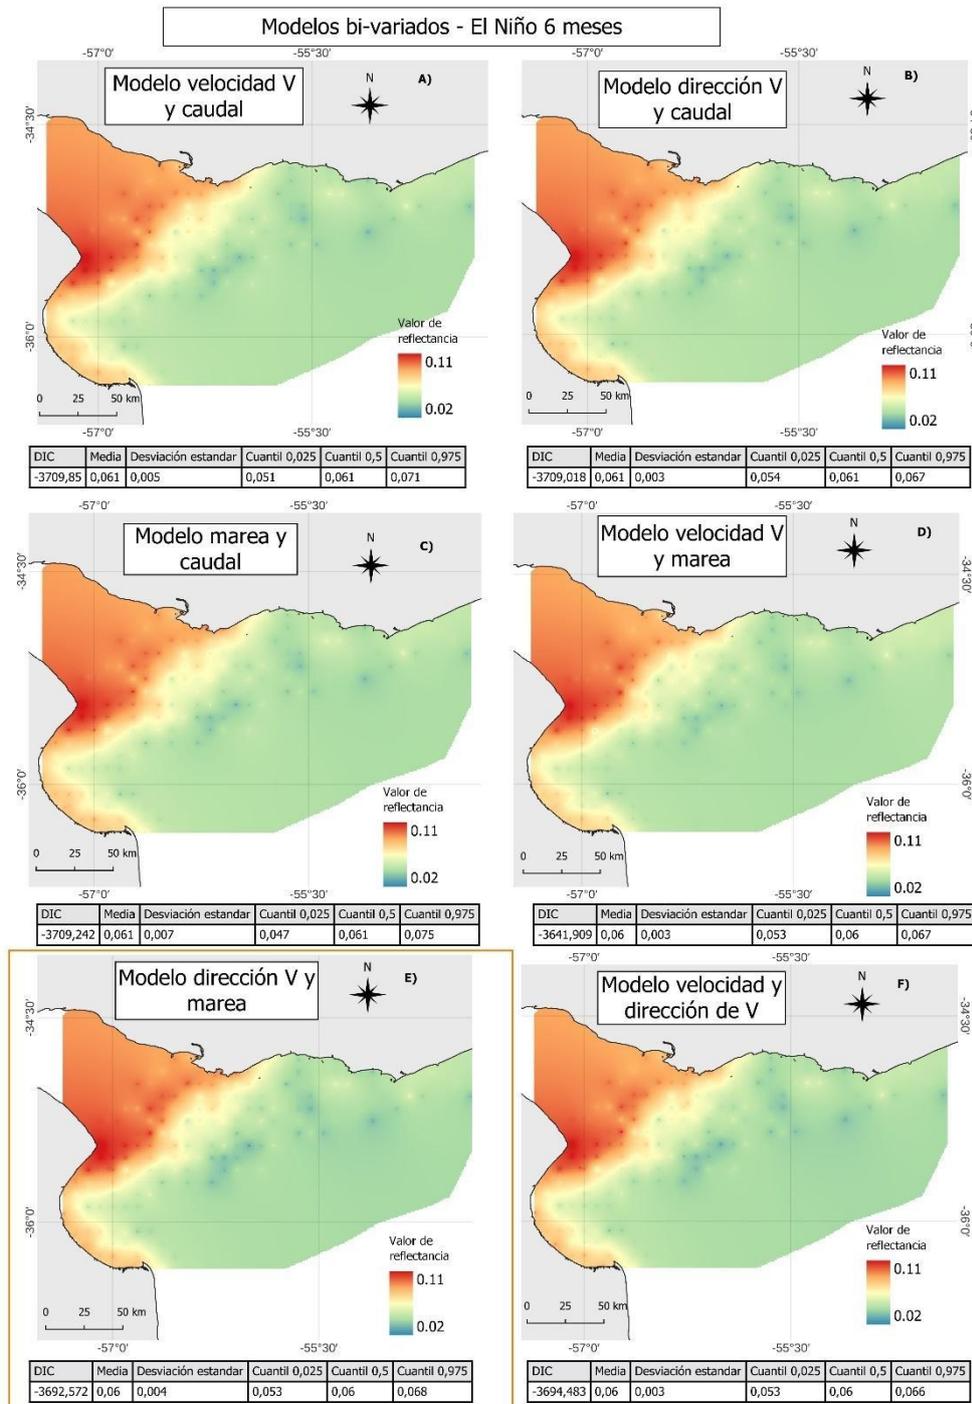


Figura 27: Salida gráfica de los modelos bivariados en evento El Niño escala temporal 6 meses. A) Modelo que combina dirección del viento y caudal. B) Modelo que combina velocidad de viento y caudal C) Modelo que combina marea y caudal. D) Modelo que combina velocidad de viento y marea. E) Modelo que combina dirección de viento y marea F) Modelo con la variables velocidad y dirección de viento. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

En los modelos trivariados el que obtuvo mayor rendimiento es el que combina las variables marea, dirección y velocidad del viento. Las salidas gráficas de todos los modelos trivariados presentan los mismos patrones espaciales ([Figura 28](#)).

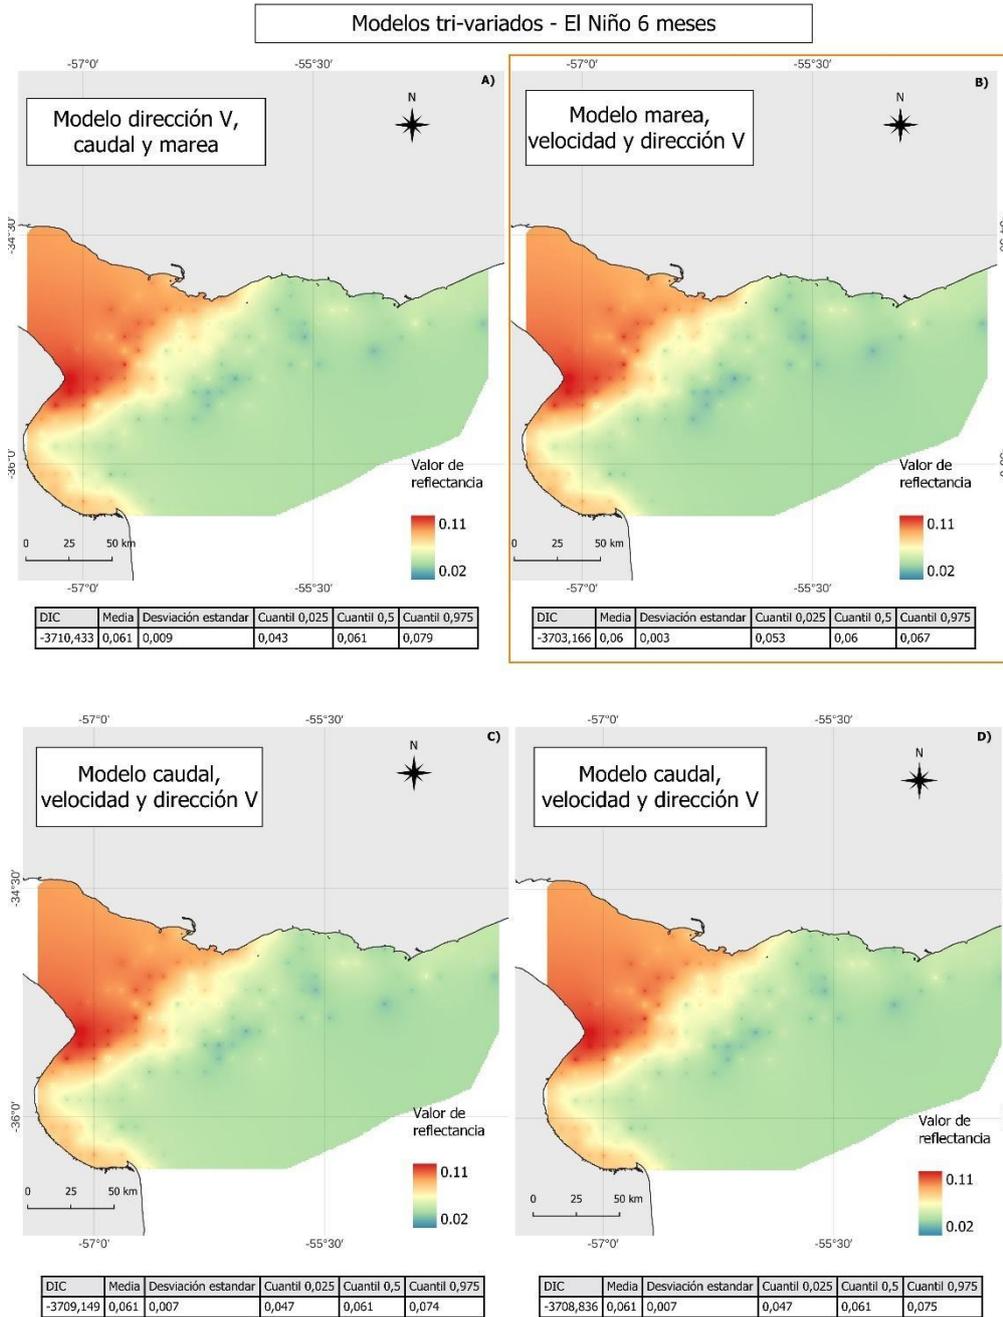


Figura 28: Salida gráfica de los modelos trivariados en evento El Niño escala temporal 6 meses. A) Modelo con las variables dirección del viento, cauda y mareal. B) Modelo que combina marea, velocidad y dirección de viento. C) Modelo que combina caudal, velocidad y dirección de viento. D) Modelo que combina las variables caudal, velocidad y dirección de viento. Debajo de cada salida gráfica se muestran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

El modelo tetravariado presenta valores de DIC similares a los valores de los modelos trivariados y comparte los patrones espaciales en la salida gráfica.

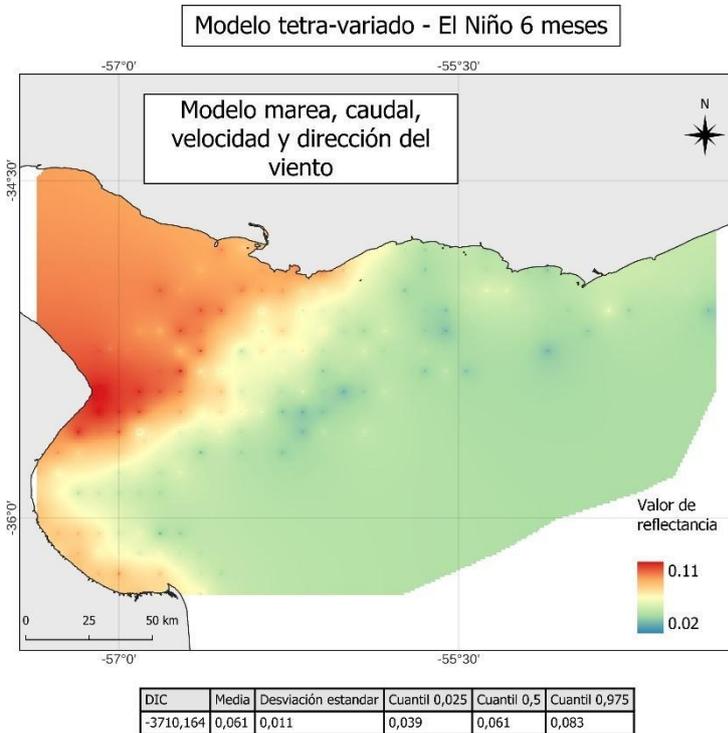


Figura 29: Modelo tetra- variado en evento El Niño para escala temporal 6 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo.

La Niña

Los modelos univariados para La Niña en la escala temporal de 6 meses ([Figura 30](#)) muestran un rendimiento similar a los modelos univariados ([Figura 14](#)) y bivariados ([Figura 15](#)) establecidos para la escala temporal de 3 meses. En las salidas gráficas se sigue manteniendo el patrón donde se el modelo con la variable caudal tiene mayor definida la zona de turbidez, pero la diferencia con la salida del modelo de dirección de viento no es significativa.

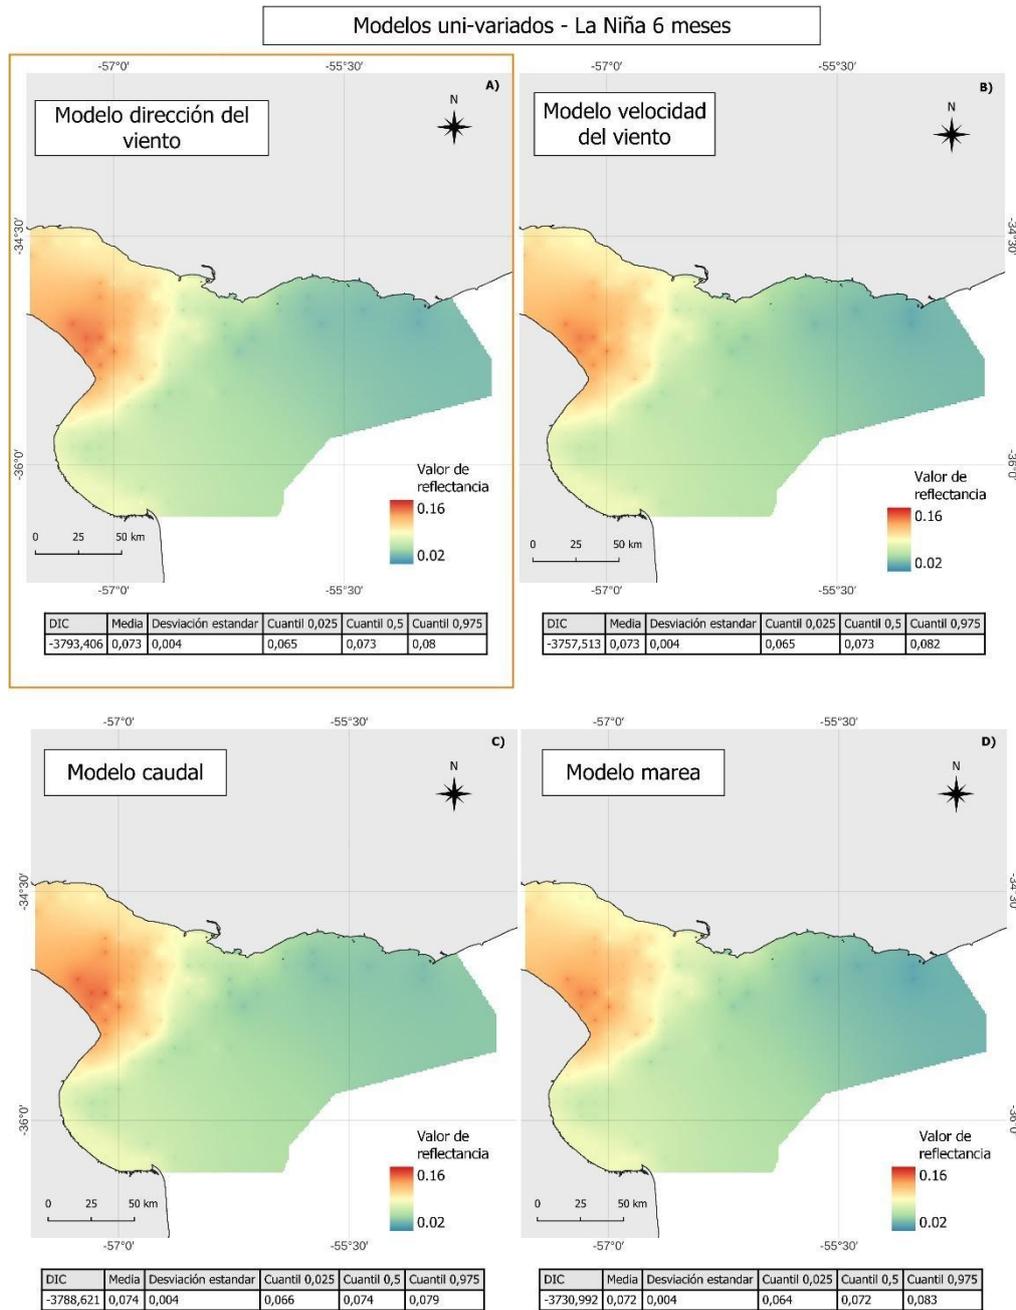


Figura 30: Salida gráfica de los modelos univariados en evento La Niña para escala temporal 6 meses. a) Modelo que incluye a dirección del viento. b) Modelo que incluye a velocidad de viento c) Modelo que incluye variable caudal. d) Modelo que incluye a marea. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

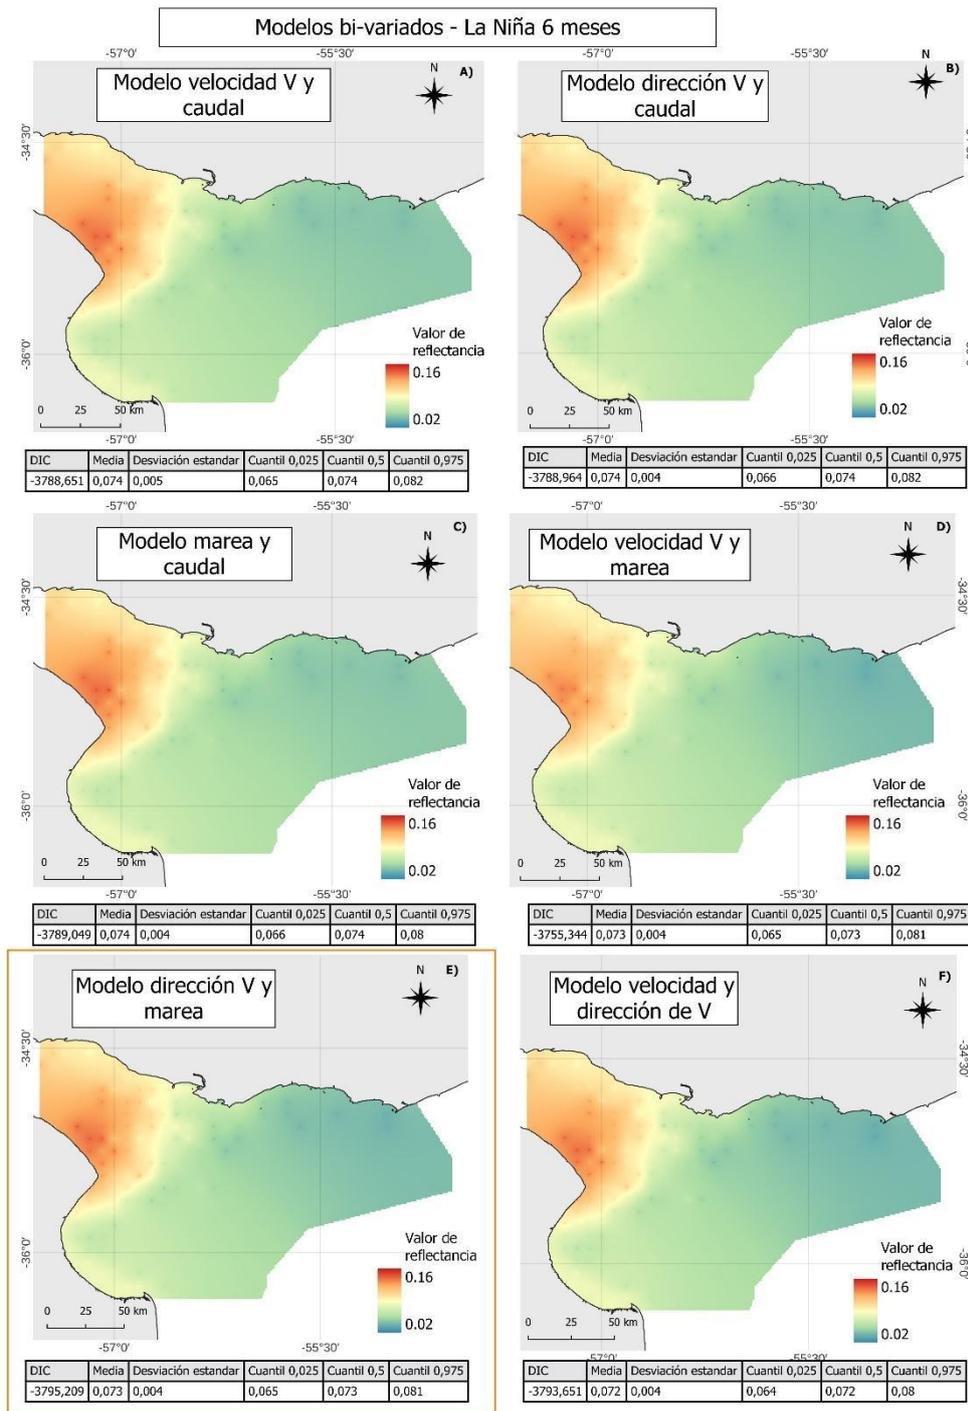


Figura 31: Salida gráfica de los modelos bivariados en evento La Niña para escala temporal de 6 meses. A) Modelo que combina dirección del viento y caudal. B) Modelo que combina velocidad de viento y caudal C) Modelo que combina marea y caudal. D) Modelo que combina velocidad de viento y marea. E) Modelo que combina dirección de viento y marea. F) Modelo que combina velocidad y dirección de viento. Debajo de cada salida gráfica se encuentran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

Cuando se modelan las tres variables, el modelo con mayor rendimiento es el que considera las variables caudal, dirección de viento y marea. El modelo de menor rendimiento difiere en esta escala temporal siendo el modelo que contempla las variables marea, dirección y velocidad del viento. Al modelar tres ([Figura 32](#)) y cuatro variables ([Figura 32](#)) se observa que las salidas gráficas no se estabilizan y no presentan diferencias significativas entre ellas quedando el frente de turbidez representado en la misma zona y con la misma forma.

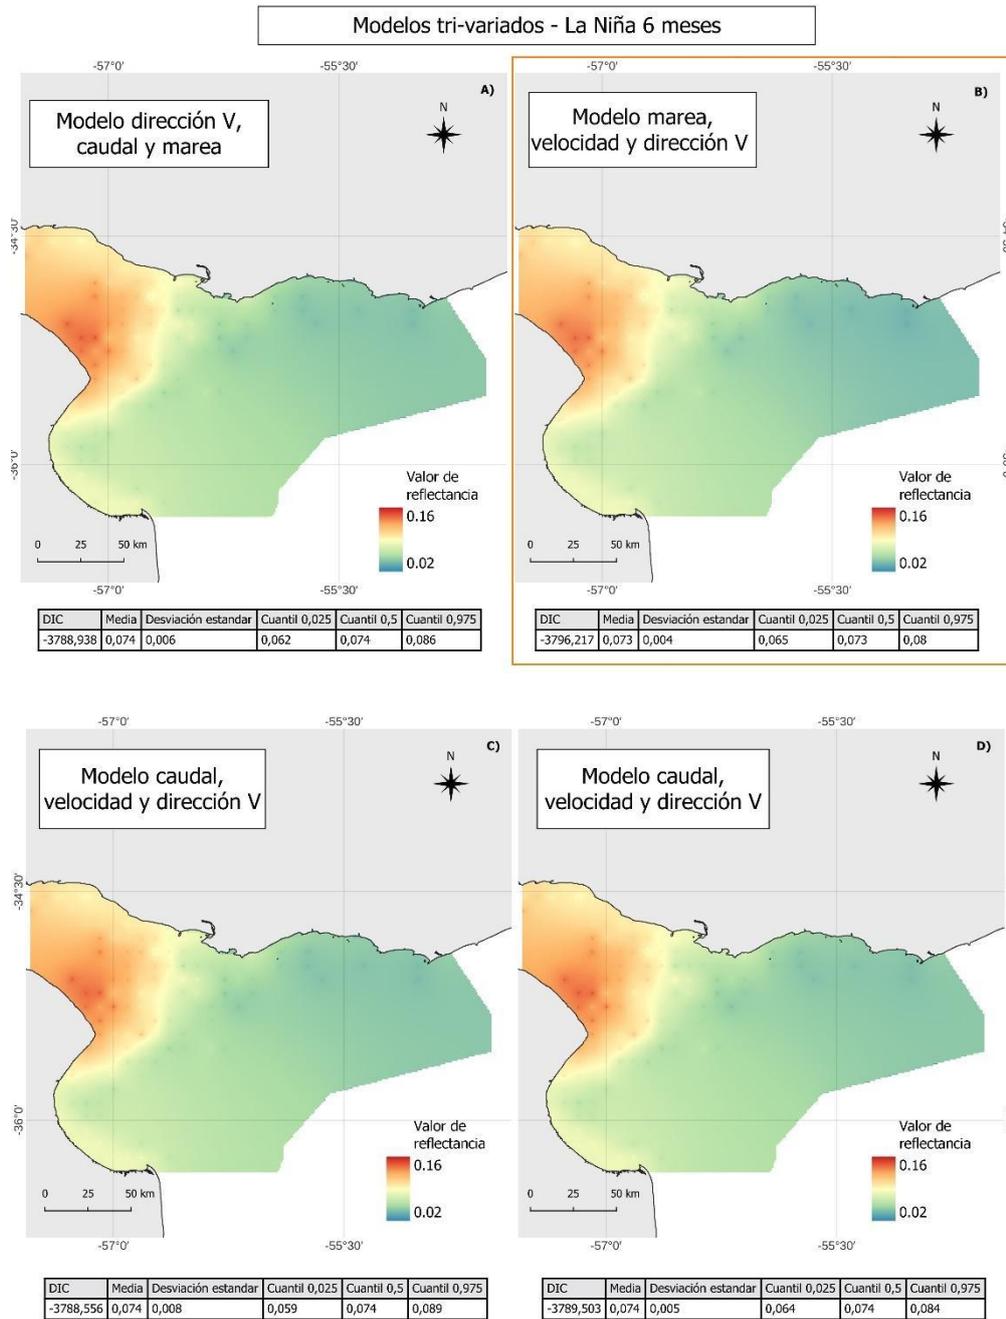


Figura 32: Salida gráfica de los modelos trivariados en evento La Niña para escala temporal de 6 meses. A) Modelo con la variables dirección del viento, cauda y mareal. B) Modelo que combina marea, velocidad y dirección de viento. C) Modelo que combina caudal, velocidad y dirección de viento. D) Modelo que combina las variables caudal, velocidad y dirección de viento. Debajo de cada salida gráfica se muestran los valores de DIC de cada modelo y el intervalo de confianza del mismo. En naranja se recuadra el modelo con mayor rendimiento.

El modelo tetra variado para La Niña ([Figura 33](#)) presentó un rendimiento similar al modelo tri variado que combinó caudal, dirección del viento y marea.

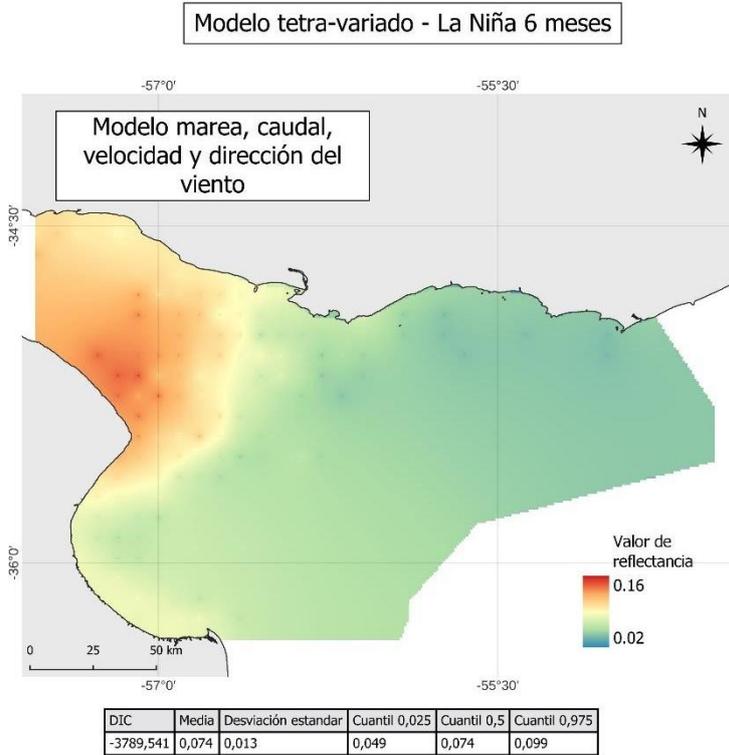


Figura 33: Modelos tetra- variados en evento La Niña para escala temporal 6 meses. Modelo que combina marea, caudal, velocidad y dirección del viento. Debajo de la salida gráfica se encuentran los valores de DIC del modelo y su intervalo de confianza.

8.2.4. Comparación entre salidas de los modelos e imágenes satelitales

Para ambos eventos (El Niño/La Niña) los modelos indican que las zonas de mayor turbidez se van acentuando a medida que son incorporadas más variables explicativas al modelo. Durante El Niño, la pluma de turbidez alcanzó hasta el departamento de Canelones en su extremo norte, con zonas de mayor concentración de sedimentos en suspensión en la zona de Punta Colorada y al sur se extiende hasta el Cabo de San Antonio. Por el contrario, durante La Niña se observa una retracción de la pluma de descarga ubicándose frente al departamento de San José en su extremo norte y frente

a Punta Indio en su extremo sur ([Figura 34](#)). Para ambos eventos en la escala temporal de 4 meses es donde se observa una menor distancia entre el frente de turbidez representado en la salida gráfica del modelo y el frente de turbidez extraído a partir de las imágenes satelitales el cual se encuentra representado en la figura 32 por una línea negra y el frente de turbidez secundario representado con una línea gris.

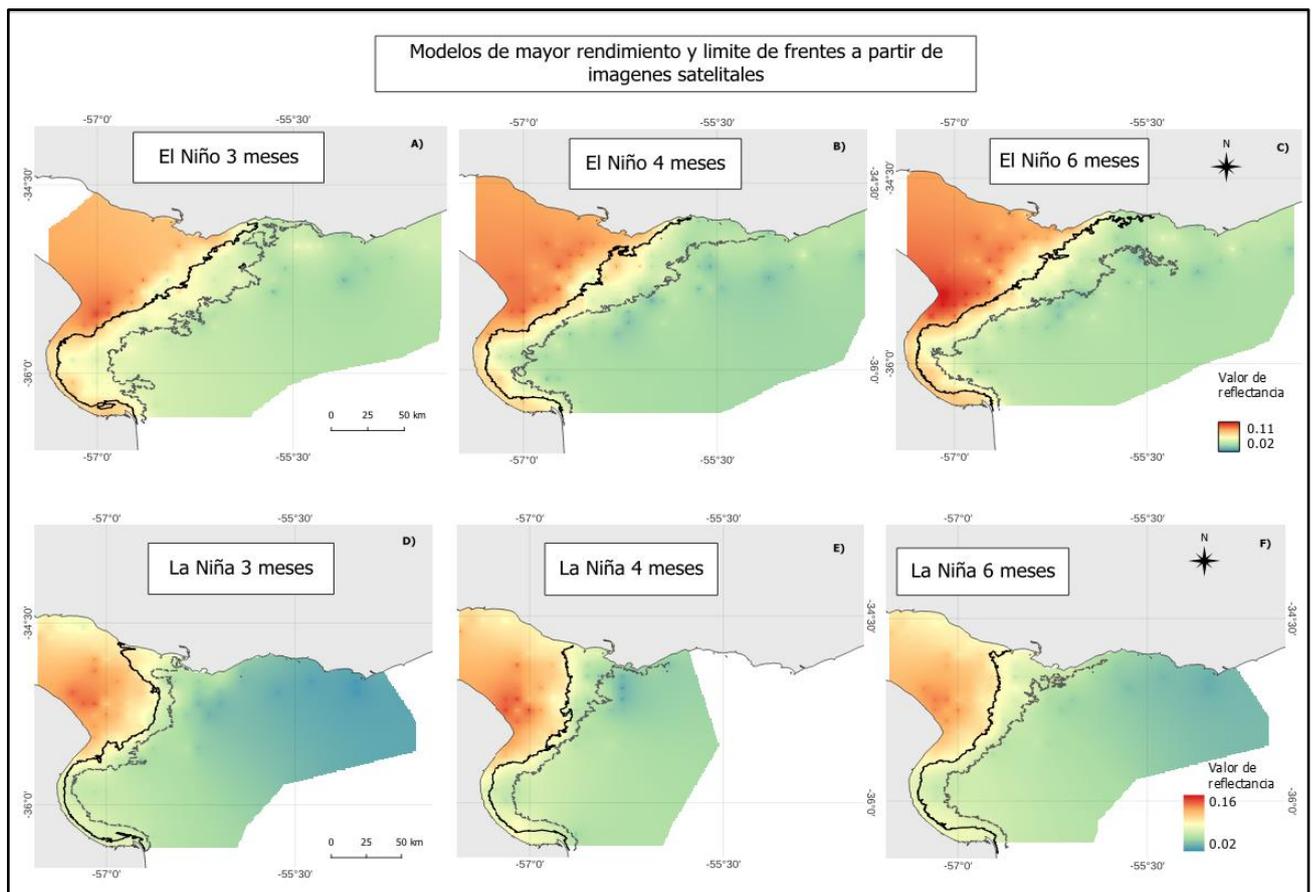


Figura 34: Comparación entre la salida de los modelos de mayor rendimiento para cada escala temporal (3, 4, 6 meses). Se indica línea del frente de turbidez principal (negra) y secundario (gris) extraída a partir del mosaico de imágenes utilizadas para cada escala temporal.

9. Discusión

Los eventos interanuales El Niño y La Niña tienen un efecto directo en la variabilidad espacial del frente de turbidez principal del Río de la Plata, afectando su posición. La presente investigación demuestra que la metodología desarrollada para detección del frente de turbidez en complemento con la aplicación de una herramienta de modelización multivariada logra representar de manera aceptable los cambios espacio-temporales del frente de turbidez principal del Río de la Plata asociados a eventos extremos El Niño/La Niña. La combinación de la estadística Bayesiana y la teledetección permitió analizar de manera integral la dinámica hidrográfica del frente de turbidez principal, considerando tanto los datos recopilados de las variables explicativas como la información obtenida a través de imágenes satelitales, contribuyendo a una mejor comprensión de este fenómeno.

Según [Maciel et al. \(2021\)](#), la variabilidad espacial del frente de turbidez, analizada para el periodo 2014-2017, estuvo explicada por efectos de forzantes climáticos y oceanográficos que actuaron en diferentes escalas temporales, siendo el caudal el principal factor mientras que la marea representa un forzante secundario. Los resultados de esta tesis están en consonancia con los hallazgos de [Maciel et al. \(2021\)](#), durante el El Niño, los modelos (desde univariados hasta multivariados) con mayores rendimientos incluyeron al caudal como variable explicativa principal, mientras que aquellos que incorporaron a la marea entre las variables explicativas mostraron el rendimiento más bajo. Para el evento La Niña, en las escalas temporales de 3 y 6 meses, los modelos con mayor rendimiento fueron aquellos que incluyeron a la dirección del viento, mientras que en la escala temporal de 4 meses, los modelos con mayores rendimientos incluyeron a la velocidad del viento. Esto se explica porque

la dirección del viento tiene un impacto directo sobre la pluma de agua dulce del Río de la Plata, generando una variabilidad estacional e interanual ([Simionato et al., 2001](#)). Cabe destacar que durante La Niña, la mayor frecuencia de vientos fuertes puede influir más en la posición del frente de turbidez ([Maciel et al., 2021](#)).

Cambios en el régimen de precipitaciones y la consecuente descarga fluvial asociada a cada fase (cálida o fría) del ENOS afecta de manera diferencial la posición del frente de turbidez ([Fossati et al., 2014](#)). Un aumento de las precipitaciones durante la fase cálida (El Niño) provoca incremento de la descarga fluvial, mientras que una disminución de las precipitaciones durante la fase fría (La Niña) reduce el aporte de agua dulce al sistema. En consecuencia, la variabilidad espacial del frente de turbidez principal del Río de la Plata está influenciada y puede ser detectada durante el desarrollo de cada una de las fases del ENOS. Durante el efecto de El Niño (fase cálida), el frente de turbidez se extiende hasta Maldonado, mientras que durante La Niña (fase fría) el frente de turbidez principal se retrae hacia San José ([Maciel et al., 2021](#)). Durante los eventos extremos El Niño (2015-2016) y las diferencias cualitativas observadas se concentran en la zona externa del estuario del Río de la Plata durante las tres escalas temporales (3, 4 y 6 meses) consideradas (ver figuras [13](#), [21](#) y [29](#)). En cambio, durante La Niña (2011-2012) la mayor variabilidad en la posición del frente de turbidez fue observada en la costa uruguaya y en la zona intermedia e interna del estuario (ver figuras [17](#), [25](#) y [33](#)). Estos resultados concuerdan con lo indicado por Dogliotti, 2016 con relación al impacto que tiene el aumento del caudal en el periodo de El Niño en la pluma de agua dulce el cual trae como consecuencia que los sedimentos lleguen más lejos en relación a períodos La Niña donde los mismos se concentran más en la parte superior y media del estuario.

El enfoque de separar los datos en diferentes escalas temporales permitió observar que los resultados más cercanos a la realidad corresponden a la escala temporal de 4 meses. Esta escala es inter-estacional ya que incluye dos meses que pertenecen a estaciones diferentes, excluyendo el mes de transición, lo que sugiere que los meses de transición pueden interferir con la calidad de los resultados debido a la alta variabilidad del frente hasta llegar a estabilizarse con un patrón estacional. Otro aspecto metodológico para destacar es que utilizando una metodología semi-cualitativa, fueron extraídos datos no solo de la posición del frente de turbidez principal, sino también de zonas de transición entre el frente y el agua clara, donde se encuentra menor concentración de sólidos suspendidos para mejorar la precisión de los resultados. Esto permitió obtener la modelización del frente de turbidez principal y también el secundario. Al comparar las imágenes satelitales y las salidas gráficas obtenidas con los modelos, es posible observar que las representaciones mediante modelización siguen los patrones espaciales, del frente secundario y la zona de transición, captados mediante imágenes satelitales (ver [Figura 34](#)). Es posible observar la extensión del frente secundario en periodos asociados al evento El Niño y la contracción asociados al evento La Niña. Esto permitió obtener salidas gráficas del modelo más precisas. Esta decisión metodológica de modelización que considera estas tres escalas temporales visibiliza la dinámica del frente de turbidez, mostrando cómo diferentes procesos operan en distintos marcos temporales y cómo estos se interrelacionan para influir en el comportamiento del frente. Se pueden observar las diferencias obtenidas en las salidas gráficas tanto en la forma del frente de turbidez respecto a la extraída de imágenes satelitales como en la definición de la representación de la pluma de agua dulce (ver [Figura 34](#)). En la escala temporal de 3

meses se puede observar menos definición que en la de 4 meses para el evento El Niño y para el evento La Niña esta diferencia se encuentra marcada entre la escala temporal de 4 y 6 meses, siendo esta última la que tiene menor definición.

Para futuros trabajos se propone adicionar la variable batimetría buscando mejorar la calidad de los modelos, ya que las mayores diferencias en comparación con el frente de turbidez extraído de las imágenes satelitales se observan en la zona de la Barra del Indio. A futuro, esta metodología puede permitir generar modelos de diferentes escenarios predictivos apenas cambiando los valores de las variables explicativas, constituyendo así una herramienta potente y valiosa para la comprensión de la variabilidad del frente de turbidez, así como para la planificación espacial costera y la gestión territorial. Una gestión costera integrada demanda consideraciones relativas a la dinámica del frente de turbidez del Río de la Plata. Conocer y entender la respuesta del frente de turbidez frente a eventos extremos permite un mejor entendimiento de la calidad del agua, ya que altos niveles de turbidez pueden estar asociados con la presencia de contaminantes, sedimentos y materia orgánica en suspensión, los cuales son indicadores de la salud del ecosistema acuático. Poder evaluar estas situaciones permite tomar decisiones informadas sobre la gestión del agua y la protección de los recursos naturales ([Freplata, 2005](#)). La detección de la posición del frente de turbidez y la predicción de su dinámica temporal puede ayudar a una mejor gestión de diversas fuentes de contaminantes que descargan en el Río de la Plata y que están asociadas a diferentes zonas, locales o remotas, de la amplia Cuenca del Plata. Esto es crucial para implementar políticas de control y mitigación, especialmente en áreas donde las descargas de aguas residuales y otros contaminantes son comunes ([Freplata, 2005](#)). La turbidez y la calidad del agua son

factores que deben considerarse al planificar o desarrollar infraestructuras costeras (tales como puertos, usinas, rutas y edificaciones, entre otros) en áreas cercanas al estuario y así como con la planificación del impacto que puedan tener esas obras en la población. Considerar estos aspectos aporta a evitar daños ecológicos y a garantizar que las infraestructuras sean sostenibles a largo plazo.

La estadística Bayesiana resultó una herramienta beneficiosa y potente para abordar este estudio de caso, permitiendo considerar la correlación espacial de los datos e incorporar variables de diferentes fuentes de datos, lo cual es una ventaja comparativa frente a otras metodologías estadísticas. En este trabajo quedó demostrado que la capacidad de los modelos bayesianos para incluir efectos aleatorios y variables explicativas diversas permitió una representación más realista de la dinámica estuarina. Además, la metodología Bayesiana utilizada, a través del paquete R-INLA, facilitó la implementación de modelos complejos con rapidez y eficiencia, permitiendo pruebas exhaustivas para seleccionar las configuraciones más adecuadas para cada modelo. Otros factores que aportan a la robustez de la modelización son la distribución previa (a priori) de los datos, el tamaño del conjunto de datos, los efectos de borde y la estructura espacial de los datos. Estos aspectos permiten generar resultados que se acerquen más a la realidad. Otra ventaja comparativa que presenta la utilización del paquete R-INLA es la capacidad de incorporar distribuciones a los datos, como por ejemplo los modelos de campo aleatorio gaussiano (GMRF, por sus siglas en inglés), siendo una herramienta que permite modelar estructuras complejas de dependencia espacial y temporal. Estos modelos bayesianos, a diferencia de los modelos frecuentistas, permiten incorporar efectos aleatorios que varían en el espacio y el tiempo, lo que es fundamental para capturar patrones de variabilidad en los datos

[\(Chasco & López, 2004\).](#)

10. Conclusiones

El desarrollo metodológico aplicado en esta tesis demuestra que la modelización basada en estadística Bayesiana presenta diversas ventajas para abordar el problema de investigación aquí planteado. Por un lado, permite incorporar información previa sobre las variables que se van a utilizar, lo cual genera resultados más precisos y permite modelar aún con pocos datos. Esto se pudo ver reflejado en los resultados cuando se obtuvo una mejor representación de la realidad en la escala temporal de 4 meses y no en la de 6 meses. Por lo que prevalece la calidad del dato frente a la cantidad de estos.

Se logró representar el impacto que tienen los eventos El Niño y La Niña, en la posición del frente de turbidez del Río de la Plata. Las salidas gráficas durante El Niño muestran al frente de turbidez hacia la zona intermedia y exterior del estuario, mientras que durante La Niña se observa como se retrae el frente hacia áreas más internas del estuario. Esta variabilidad espacio-temporal es capturada de manera más precisa gracias a la combinación de modelos bayesianos y la teledetección, que permitieron una visión integral de la dinámica hidrográfica.

Los modelos bayesianos también permiten incorporar diversas variables y fuentes de datos, lo que facilitó la inclusión de variables de distinta naturaleza, generando modelos complejos que representan la interacción entre las variables. El mayor rendimiento de la variable caudal durante El Niño y el de las variables dirección y velocidad del viento durante La Niña, resaltó la importancia de identificar combinaciones óptimas de variables para mejorar la precisión de la predicción en diferentes eventos climáticos y escalas temporales.

En cuanto a la implementación de la metodología planteada, se observó que la extracción de puntos de la zona de mayor turbidez del frente y de la zona de menor turbidez, situado hacia el límite del frente, permitió captar el gradiente de cambio, lo cual hizo que los resultados fueran más precisos. A futuro, si se cuenta con procesadores de alto rendimiento, podría realizarse la extracción automática de la pluma de turbidez del Río de la Plata mediante procesamientos en Google EarthEngine, asegurando así que los resultados sean aún más exactos. Asimismo, la incorporación de la variable batimetría y la interpolación de valores de productos satelitales de viento mejoraría la calidad de los modelos, especialmente en áreas críticas como la Barra del Indio.

Este trabajo destaca la importancia de comprender las interacciones entre las variables en los modelos multivariados y refuerza la utilidad de la estadística Bayesiana como una herramienta poderosa y flexible para la modelización de fenómenos complejos como el frente de turbidez del Río de la Plata.

11. Bibliografía

- Acha, E. M., & Mianzan, H. (2003). El estuario del Plata: donde el río se encuentra con el mar. *Ciencia Hoy*, 13(73), pp. 10-20.
- Acha, E. M., Piola, A., Iribarne, O., & Mianzan, H. (2015). *Ecological processes at marine fronts: oases in the ocean*. Springer.
- Angelescu, V. A., & Sánchez, R. P. (1997). *Exploraciones oceanográficas y pesqueras en el Mar Argentino y la región adyacente del Atlántico Sudoccidental (años 1874-1993)*.
- Bernden, G. (2016). Estudio de la relación entre turbidez y concentración de sedimentos en suspensión en función de la granulometría en el Río de la Plata
- DOI - 10.13140/RG.2.2.11183.56489
- Blangiardo, M., & Cameletti, M. (2015). *Spatial and spatio-temporal Bayesian models with R-INLA*. John Wiley & Sons.
- Bidegain Dorelo, M., Pasten, M., Nagy Breitenstein, G. J., Coronel, G., Ferrer, J., & Arana, I. (2017). Tendencias recientes de las precipitaciones e impactos asociados con ENSO en la cuenca del Río de la Plata. *Paraquaria Natural*, 2017, 5 (2): 8-18.
- Boschi, E. (1987) El ecosistema estuarial del Río de la Plata (Argentina y Uruguay). En *anales del Instituto de ciencias del mar y limnología*, Universidad Nacional Autónoma de México.
- Buratti CC, Chidichimo MP, Cortés F, Gaviola S, Martos P, Prosdocimi L, Seitune D, Verón E (editores). 2022. Estado del conocimiento de los efectos del cambio

climático en el Océano Atlántico Sudoccidental sobre los recursos pesqueros y sus implicancias para el manejo sostenible. Ministerio de Agricultura, Ganadería y Pesca. 225 pp.

Chasco, C., & López, F. A. (2004). Modelos de regresión espacio-temporales en la estimación de la renta municipal: el caso de la Región de Murcia. *Estudios de economía aplicada*, 22(3), 0.

Chuvieco, E. (1991). Fundamentos de teledetección espacial. *Estudios Geográficos*, 52(203), 371.

Dogliotti, A.I., K.G. Ruddick, B. Nechad, D. Doxaran, E. Knaeps (2014). A single algorithm to retrieve turbidity from remotely sensed data in all coastal and estuarine waters. *Remote Sensing Of Environment* 156 (2015) 157–168.

Dogliotti A.I., Ruddick K., Guerrero R.A. 2016. *Estuary Continental Shelf Research*, 182 (A), 27-39.

Echevarría, L., Gómez, A., Gómez Erache, M., & Tejera, R. (2016). La planificación espacial marina como herramienta de gestión. *Interdisciplinarias* 2015; 4.

Frías, M. I. (2022). Modelo de predicción de alturas del agua en el Río de la Plata. Web

Framiñan M, & O Brown, 1996. *Continental Shelf Research* 16, 1259-1282.

Framiñan, M. B., Etala, M. P., Acha, E. M., Guerrero, R. A., Lasta, C. A., & Brown, O. B. (1999). Physical characteristics and processes of the Río de la Plata estuary. In *Estuaries of South America: their geomorphology and dynamics* (pp. 161-194). Berlin, Heidelberg: Springer Berlin Heidelberg.

- Franco, B. C., Defeo, O., Piola, A. R., Barreiro, M., Yang, H., Ortega, L., Möller, O. O., 2020. Climate change impacts on the atmospheric circulation, ocean, and fisheries in the southwest South Atlantic Ocean: a review. *Climatic Change*, 1-19. <https://doi.org/10.1007/s10584-020-0>
- Follegati, R (1980). *Geografía Marina*. Revista Marina 738, Armada Naval de Chile pp. 498 – 502
- Fossati, M., Cayocca, F., & Piedra-Cueva, I. (2014). Fine sediment dynamics in the Río de la Plata. *Advances in geosciences*, 39, 75-80.
- Freplata (2005). Análisis Diagnóstico Transfronterizo del Río de la Plata y su Frente Marítimo. Proyecto PNUD/GEF/ RLA/99/G 31. www.freplata.org/documentos.
- García-Sánchez, R., & González-Farías, G. (2018). Análisis bayesiano. Conceptos básicos y prácticos para su interpretación y uso. *Revista de la Facultad de Ingeniería*, 33(3), 205-215. <https://doi.org/10.24275/10.24275/rfi.v33i3.1399>
- Gutiérrez, O. (2016). *Dinámica sedimentaria en la costa uruguaya. Un abordaje desde la geografía histórica y los sig para comprender las tendencias evolutivas vinculadas al cambio global* (Doctoral dissertation, Universidad Internacional de Andalucía).
- Hernández J.F., B.L. Hernández (2003). Aplicación de Técnicas de Teledetección al estudio de la turbidez de las aguas litorales en la costa oriental de Gran Canaria mediante un modelo teórico. *Vegueta*, Numero 7, pg 229.
- Lalinde, J. D. H., Castro, F. E., Rodríguez, J. E., Rangel, J. G. C., Sierra, C. A. T.,

Torrado, M. K. A., ... & Pirela, V. J. B. (2018). Sobre el uso adecuado del coeficiente de correlación de Pearson: definición, propiedades y suposiciones. Archivos venezolanos de Farmacología y Terapéutica, 37(5), 587-595.

López-Montecinos, C. (2019). Fundamentos básicos para la teledetección ambiental. Cartografía Ambiental y Sistemas de Información Geográfica.

Maciel, F., Santoro, P., Piedra Cueva, I., & Pedocchi, F. (2018). Validación sinóptica de un modelo hidrodinámico del Río de la Plata mediante teledetección del frente de turbidez. In XXVIII Congreso Latinoamericano de Hidráulica, Buenos Aires, Argentina, Sep. 2018..Instituto Nacional del Agua.

Maciel, F., & Pedocchi, F. (2019). Evaluation of satellite spectral signatures to retrieve water quality parameters using different atmospheric corrections in the Río de la Plata turbid waters. In 2019 International Ocean Colour Science Meeting. Busan, South Korea, 9-12 April 2019.. IOCS.

Maciel, F. P., Santoro, P. E., & Pedocchi, F. (2021). Spatio-temporal dynamics of the Río de la Plata turbidity front; combining remote sensing with in-situ measurements and numerical modeling. Continental Shelf Research, 213, 104301.

Maciel, F. P., Haakonsson, S., Ponce de León, L., Bonilla, S., & Pedocchi, F. (2023). Satellite monitoring of chlorophyll-a threshold levels during an exceptional cyanobacterial bloom (2018-2019) in the Río de la Plata. Ribagua, 1-17.

MATHER, P. (1993). A Review of: "*Remote Sensing and Geographical Information Systems for Resource Management in Developing Countries*".: Edited by A. S. BELWARD and C. R. VALENZUELA. (Dordrecht: Kluwer Academic Publishers, 1991) [Pp. 506.]. *International Journal of Remote Sensing*, 14(3), 599–600. <https://doi.org/10.1080/01431169308904359>

Maturana, J., Bello, M., & Manley, M. (1997). Antecedentes históricos y descripción del fenómeno El Niño, Oscilación del Sur. *El Niño-La Niña*, 2000, 13-27.

Meccia, V. L. (2008). Estudios de la circulación forzada por el viento en el estuario del Río de la Plata y sus implicancias en la estratificación: resultados del análisis de datos y simulaciones numéricas (Doctoral dissertation, Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales).

Mirás, B (2019). Modelo espacial Bayesiano para la estimación de la invalidez en España con la metodología INLA. Tesis de maestría, Universidad Carlos III de Madrid.

Monsalve N, 2013. Modelos jerárquicos bayesianos espaciales en epidemiología agrícola., Tesis doctoral, Universidad Politécnica de Valencia. 1-35.

Nagy, G. J., Severov, D. N., Pshennikov, V. A., De los Santos, M., Lagomarsino, J. J., Sans, K., & Morozov, E. G. (2008). Rio de la Plata estuarine system: relationship between riverflow and frontal variability. *Advances in Space Research*, 41(11), 1876-1881.

O'Donnell, J. (1993). Surface fronts in estuaries: a review. *Estuaries*, 16, 12-39.

Olmo, M. C., Espejo, F. R., Hernández, F. A., de la Cámara, M. J. G., González-

- Anleo, A. F. R., Madueño, J. M., ... & Rodríguez, E. S. (1999). Técnicas de Teledetección aplicadas al estudio de los ríos Tinto y Odiel. In Teledetección: avances y aplicaciones (pp. 59-62). Diputación de Albacete.
- Piedra Cueva, I; Fossati, M. (2003). FREPLATA. Simulación numérica de la distribución estacional del frente salino. Obtenido de Instituto de Mecánica de Fluidos e Ingeniería Ambiental (IMFIA). : www.freplata.org
- Piccolo, M. C., & Perillo, G. M. (1997). Geomorfología e hidrografía de los estuarios.
- Ré, M., & Menéndez, Á. N. (2003). Modelo Numérico Del Río De La Plata Y Su Frente Marítimo Para La Predicción De Los Efectos Del Cambio Climático. *Mecánica Computacional*, 354-367.
- Rendón-Macías, Mario Enrique, Riojas-Garza, Alberto, Contreras-Estrada, Daniela, & Martínez-Ezquerro, José Darío. (2018). Análisis bayesiano. Conceptos básicos y prácticos para su interpretación y uso. *Revista alergia México*, 65(3), 285-298. <https://doi.org/10.29262/ram.v65i3.512>
- Rue, H., Martino, S., Chopin, N. 2009. *Journal of Royal Statistical Society, Series B*, 71, 319-392.
- Ruiz D. (2017). Método de Estimación de Sólidos Suspendidos Totales como Indicador de la Calidad del Agua Mediante Imágenes Satelitales. Universidad Nacional de Colombia Facultad de Ciencias Agrarias, Escuela de posgrado Bogotá, Colombia.
- Sánchez García, A., & Toral Ruiz, N. (2014). Análisis de las capacidades de los

sistemas Landsat y E01 para la actualización cartográfica. Estudio de un casopráctico.

Schowengerdt, R. A. (2006). Remote sensing: models and methods for image processing. AcademicPress.

Simpson, E., & Schuhen, N. (2023). High-dimensional modeling spatial and spatio-temporal conditional extremes using INLA and Gaussian Markov Random Fields. *Extremes*, 1-33. <https://doi.org/10.1007/s10687-023-00468-8>

Simionato, C. G., Nuñez, M. N., & Engel, M. (2001). The salinity front of the Río de la Plata-A numerical case study for winter and summer conditions. *GeophysicalResearchLetters*, 28(13), 2641-2644.

Simionato, C. G., Moreira, D., Re, M. y Fossati, M., 2011 b. Estudio de la dinámica hidro-sedimentológica del Río de la Plata: observación y modelación numérica de los sedimentos finos. 109pp. Publicado por Proyecto FREPLATA, CTMFM-CARP, ISBN978-92- 990052-9-3

Vermote, E. (2015). MYD09Q1 MODIS/Aqua Surface Reflectance 8-Day L3 Global 250m SIN Grid V006 [Data set]. NASA EOSDIS Land Processes DAAC. Accessed 2019-12-09 from <https://doi.org/10.5067/MODIS/MYD09Q1.006>

Referencias Electrónicas

EuropeanSpace Agency (ESA), 2009, https://www.esa.int/SPECIALS/Eduspace_ES/SEMO1U3FEXF_2.html Ultimo acceso: 06/08/2023

Google Earth Engine. (2023). <https://earthengine.google.com/> Ultimo acceso: 12/08/2023

Instituto Nacional del Agua (INA), 2003 https://www.ina.gov.ar/pdf/LH-Info_FRE_LHA-02-216-03_FrePlata-ParanaNino_Feb_2003.pdf. Último acceso: 06/08/2023

Laboratorio ambiental marino del Pacifico, NOAA. Página temática de El Niño, 2019 <https://www.pmel.noaa.gov/elnino/>

R – INLA Project, 2023 <https://www.r-inla.org/> Ultimo acceso: 23/08/2023

EduSat, Universidad de Girona, 2024 <https://www.edusat.com/teledeteccion/>? Último acceso: 12/10/2024

© 2015 SOPHIA, Conocimiento para la gestión del ambiente marino. https://www.sophia-mar.pt/pt/recursos_pedagogicos/1 Último acceso: 12/10/2024

12. Anexos

12.1. Pruebas y decisiones metodológicas.

El desarrollo de la metodología propuesta comenzó con la descarga de las imágenes MODIS Aqua diarias, seguido de la generación de seis puntos a lo largo del frente de turbidez para llevar a cabo clasificaciones no supervisadas y detectar su posición. Luego, se realizó una búsqueda de algoritmos que trabajan con las propiedades ópticas de las imágenes, razón por la cual se optó comenzar a utilizar productos de MODIS Aqua con correcciones atmosféricas.

Posteriormente, se tomó la decisión de trabajar con R-INLA, se realizaron pruebas utilizando datos del período 2011-2019 para identificar el año con mayor sensibilidad a los cambios y realizar ajustes en la metodología. Luego de meses de capacitación, se optó por utilizar Google Earth Engine en lugar de un SIG de escritorio, lo que permitió extraer de forma más rápida y eficiente datos de reflectancia de las imágenes y generar diversos mosaicos para evaluar y seleccionar escalas temporales de análisis.

En cuanto a las pruebas realizadas, se compararon imágenes diarias con el compuesto de 8 días, junto con datos diarios de las variables explicativas. No se encontraron diferencias significativas, por lo que se eligió utilizar el compuesto de 8 días, que permite rescatar más imágenes durante los eventos El Niño, cuando hay un mayor desarrollo del evento pero también mayor presencia de nubosidad obligando a descartar muchas fechas del análisis.

También se experimentó con la modelación de datos de reflectancia con la banda del espectro correspondiente al infrarrojo, pero los resultados no fueron satisfactorios, por

lo que se continuó trabajando con la banda del rojo.

En el análisis de escalas temporales, se evaluaron los datos de cada año completos de manera independiente y conjunta, lo que permitió comprender la dinámica estuarina y establecer criterios de selección de escalas temporales para este estudio.

El trabajo inicialmente identificó seis puntos a lo largo del frente de turbidez principal, que posteriormente se incrementaron a doce. En una una etapa siguiente se incorporaron puntos en las zonas del frente de turbidez secundario lo cual mejoró la predicción y precisión del modelo al representar los gradientes de cambio entre zonas con mayor y menor turbidez.

En cuanto a las fórmulas de modelos utilizados se realizaron pruebas con diferentes distribuciones de los datos y diferentes interpoladores

12.2. Número de imágenes utilizadas por mes, durante los tres períodos (3, 4 y 6 meses) considerados como ventanas temporales de desfase entre el desarrollo de los eventos El Niño/La Niña en la cuenca del océano Pacífico y la llegada de su impacto a la zona de Río de la Plata.

		3 meses	4 meses	6 meses
La Niña	2011	Febrero (3)	Enero (2)	Enero 2
		Marzo (4)	Febrero (3)	Febrero 3
		Abril (3)	Abril (3)	Marzo 4
			Mayo (3)	Abril 3
				Mayo 3
				Junio 2
	2012	Febrero (4)	Enero (4)	Enero 4
		Marzo (4)	Febrero (4)	Febrero 4
		Abril (3)	Abril (3)	Marzo 4
			Mayo (1)	Abril 3
				Mayo 1
				Junio 4

El Niño	2015	Agosto(3)	julio 3	julio 3
		Setiembre (3)	agosto 2	agosto 2
		Octubre (2)	octubre 2	Setiembre 2
			noviembre 4	octubre 2
				noviembre 4
				diciembre 4
	2016	Abril (3)	marzo 4	marzo 4
		Junio (4)	abril 3	abril 3
		Julio (2)	julio 2	junio 4
			agosto 3	julio 2

				agosto 3
				Setiembre 4

12.3. Fechas de imágenes utilizadas para los meses con mayor desarrollo de los eventos interanuales **El Niño (2015-2016) y **La Niña (2011-2012)**.**

El Niño	2015	13/08/2015	12/07/2015	12/07/2015	
		21/08/2015	20/07/2015	20/07/2015	
		29/08/2015	28/07/2015	28/07/2015	
		06/09/2015	21/08/2015	21/08/2015	
		14/09/2015	29/08/2015	29/08/2015	
		16/10/2015	16/10/2015	06/09/2015	
		24/10/2015	24/10/2015	14/09/2015	
			01/11/2015	16/10/2015	
			09/11/2015	24/10/2015	
			17/11/2015	01/11/2015	
			25/11/2015	09/11/2015	
				17/11/2015	
				25/11/2015	
				03/12/2015	
				11/12/2015	
				19/12/2015	
				27/12/2015	
		2016	14/04/2016	05/03/2016	05/03/2016
			22/04/2016	13/03/2016	13/03/2016
			30/04/2016	21/03/2016	21/03/2016
			01/06/2016	29/03/2016	29/03/2016
			09/06/2016	14/04/2016	14/04/2016
			17/06/2016	22/04/2016	22/04/2016
			25/06/2016	30/04/2016	30/04/2016
			03/07/2016	03/07/2016	01/06/2016

		11/07/2016	11/07/2016	09/06/2016
			04/08/2016	17/06/2016
			12/08/2016	25/06/2016
			20/08/2016	03/07/2016
				11/07/2016
				04/08/2016
				12/08/2016
				20/08/2016
				02/09/2016
				13/09/2016
				21/09/2016
				29/09/2016

La Niña	2011	02/02/2011	01/01/2011	01/01/2011
		10/02/2011	09/01/2011	09/01/2011
		26/02/2011	02/02/2011	02/02/2011
		06/03/2011	10/02/2011	10/02/2011
		14/03/2011	26/02/2011	26/02/2011
		22/03/2011	07/04/2011	03/06/2011
		30/03/2011	15/04/2011	14/03/2011
		07/04/2011	23/04/2011	22/03/2011
		15/04/2011	01/05/2011	30/03/2011
		23/04/2011	09/05/2011	07/04/2011
			25/05/2011	15/04/2011
				23/04/2011
				01/05/2011
				09/05/2011
				25/05/2011

				02/06/2011
				26/06/2011
	2012	02/02/2012	01/01/2012	01/01/2012
		10/02/2012	09/01/2012	09/01/2012
		18/02/2012	17/01/2012	17/01/2012
		26/02/2012	25/01/2012	25/01/2012
		05/03/2012	02/02/2012	02/02/2012
		13/03/2012	10/02/2012	10/02/2012
		21/03/2012	18/02/2012	18/02/2012
		29/03/2012	26/02/2012	26/02/2012
		06/04/2012	06/04/2012	05/03/2012
		14/04/2012	14/04/2012	13/03/2012
		30/04/2012	30/04/2012	21/03/2012
			08/05/2012	29/03/2012
				06/04/2012
				14/04/2012
				30/04/2012
				08/05/2012
			01/06/2012	
			09/06/2012	
			17/06/2012	
			25/06/2012	

12.4. Script de identificación del frente de turbidez principal del Río de la plata y extracción de datos en Google Earth Engine.

```
//Selección de fechas
```

```
var mod = ee.ImageCollection("MODIS/006/MYD09A1")
```

```
.filterDate('2015-07-12', '2015-07-30')
```

```
print('Coleccion Mis', mod)

//Map.addLayer(NOAA,imageVisParam,'NOAA')

//-----Conversión a imagen-----

var Img_mod = ee.Image(mod.mean)

print('Imagen', Img_mod)

//print(Img_mod.select('sur_refl_b01').projection().nominalScale())

//var                                resolucion_espacial                                =
Img_mod.select('sur_refl_b01').projection().nominalScale()

//-----AGREGA LONGITUD Y LATITUD-----

var Img_AE = Img_mod.addBands(ee.Image.pixelLonLat()).clip(rio2)

print(Img_AE,'Img_AE')

//-----Filtro de NUBES con quality bands-----

var state_1km = Img_AE.select('state_1km')
```

```
var bit10 = state_1km.bitwiseAnd(ee.Image.constant(1024)).neq(1024)

//Map.addLayer(bit10, null, 'bit10')

var bit01 = state_1km.bitwiseAnd(ee.Image.constant(3))

//Map.addLayer(bit01, null, 'bit01')

var bit9 = state_1km.bitwiseAnd(ee.Image.constant(512))

//Map.addLayer(bit9, null, 'bit9')

var bit8 = state_1km.bitwiseAnd(ee.Image.constant(256))

//Map.addLayer(bit8, null, 'bit8')

// filtro de valores en banda sur_refl_b01

var mascara = Img_AE.select('sur_refl_b01').lt(900)

//----- SELECCIÓN DE LAS BANDAS QUE SE EXTRAE LA INFORMACIÓN-----
-----

var                               Img_AE_bands1                               =
Img_AE.select('sur_refl_b02')/('/sur_refl_b01','sur_refl_b02','sur_refl_b03',
```

```
'sur_refl_b04','sur_refl_b05','sur_refl_b06', 'sur_refl_b07','longitude','latitude')

var  Img_AE_bands  =  Img_AE.select('sur_refl_b01','sur_refl_b02','sur_refl_b03',
'sur_refl_b04','sur_refl_b05','sur_refl_b06', 'sur_refl_b07','longitude','latitude')

print(Img_AE_bands,'Img_AE_bands')

var Img_masc = Img_AE_bands.mask(mascara)

//-----VISUALIZACIÓN FALSO COLOR-----

Map.addLayer(Img_AE_bands,                {max:2200,                min:-60,
bands:["sur_refl_b01","sur_refl_b02","sur_refl_b01"]}, 'Img_AE', false)

//-----VISUALIZACIÓN COLOR VERDADERO-----

Map.addLayer(Img_AE_bands,                {max:2200,                min:-60,
bands:["sur_refl_b01","sur_refl_b04","sur_refl_b03"]}, 'Img_AE_V', false)

var pixeles = Img_AE_bands.sampleRegions({

    collection:geometry,

    properties: ['id_lote'],

    scale:10000,

});

// CLASIFICACION NO SUPERVISADA

// MUESTREAR LA IMAGEN PARA DEFNIR LOS CLUSTERS
```

```
var training = Img_AE_bands1.sample({  
  
  region: rio2,  
  
  scale: 463.3127165275,  
  
  numPixels: 10000,  
  
});  
  
// DEFINIR EL NUMERO DE CLASES  
  
var numclas = 4  
  
// ENTRENA UN CLASIFICADOR CON EL ALGORITMO K-MEANS  
  
var clusterer = ee.Clusterer.wekaKMeans(numclas).train(training);  
  
// APLICAR EL CLUSTER GENERADO PARA CLASIFICAR LA IMAGEN  
  
var ClasNosup = Img_AE.cluster(clusterer);  
  
// MOSTRAR EL CLUSTER CON COLORES ALEATORIOS  
  
print(ClasNosup,'Clasificación No Supervisada')  
  
Map.addLayer(ClasNosup.randomVisualizer(), {}, 'Clasificación No Supervisada');  
  
Map.addLayer(mascara, null, 'mascara',false)  
  
//-----EXPORTACIÓN DE LOS DATOS-----  
  
Export.table.toDrive({  
  
  collection: pixeles,  
  
  folder: 'Frente_pruebas_12',
```

```
description: '2019_0_0_',  
  
fileFormat: 'csv',  
  
});
```

```
Export.image.toDrive({  
  
  image: ClasNosup,  
  
  description: 'La_niña_4_meses',  
  
  folder: 'GEE',  
  
  //region: region,  
  
  scale: 250,  
  
  maxPixels: 1e13  
  
});
```

12.5. Script de R para aplicación de modelos R-INLA.

```
#install.packages("INLA",repos=c(getOption("repos"),INLA="https://inla.r-inla-  
download.org/R/stable"), dep=TRUE)
```

```
#inla.upgrade() # for the stable version
```

```
url <- "https://cloud.r-project.org/bin/windows/contrib/3.5/patchwork_1.0.0.zip "
```

```
install.packages(url,repos=NULL, type="source")
```

```
#####
```

```
require(grid)
```

```
require(sp)
```

```
require(spdep)
```

```
require(INLA)
```

```
require(maptools)
```

```
require(alphahull)
```

```
require(rgdal)
```

```
require(raster)
```

```
require(rgeos)
```

```
require(RColorBrewer)
```

```
require(colorspace)
```

```
require(sf)
```

```
require(gridExtra)
```

```
require(patchwork)
```

```
require(bayesplot)
```

```
require(mcmc)

#####

write.csv(data.plot, "mi_plot_ninha_4meses.csv")

write.csv(data.pred, "mi_pred_ninha_4meses.csv")

#cargo los datos

data.FTRdIP      <-      read.csv("C:/Users/Usuario/OneDrive      -
fcien.edu.uy/Documentos/R/rinla/finales/ninho_6meses.csv",header=T)

str(data.FTRdIP)

### Mapa de base

mapa<-shapefile("C:/Users/Usuario/OneDrive      -
fcien.edu.uy/Documentos/R/rinla/sud_america_cortado")

####revisando la distribuci?n de los datos para cada variable

plot(data.FTRdIP$RFL,data.FTRdIP$Marea_Mdo)

plot(data.FTRdIP$RFL,data.FTRdIP$DirV_Mel)

plot(data.FTRdIP$RFL,data.FTRdIP$IntV_Mel)

plot(data.FTRdIP$RFL,data.FTRdIP$Q_RdIP)
```

```
##### describiendo la naturaleza del dato
```

```
data.FTRdIP$source="OBS"
```

```
#Determino los limites del poligono respecto a tus datos
```

```
min.lat=min(data.FTRdIP$Lat,na.rm=T)
```

```
min.lon=min(data.FTRdIP$Lon,na.rm=T)
```

```
#genero una grilla con los limites de tus datos, cada 0.1 grado en cada direccion y 100  
cuadrados en cada direccion
```

```
#esta grilla debiese coincidir con el pixelado de tus datos oceanograficos en tamanho de  
la celda (baldosa)
```

```
gt <- GridTopology(c(min.lon,min.lat), c(0.01, 0.01), c(300, 300))
```

```
grd <- SpatialGrid(gt, proj4string=CRS("+proj=longlat"))
```

```
spix <- as(grd, "SpatialPixels")
```

```
spol <- as(spix, "SpatialPolygons") # esto es para dejar todo en formato de mapa,  
polygons
```

```
# tomo la lat y long y la traspaso a un sistema de coordenadas
```

```
pt=data.frame(x=data.FTRdIP$Lon,y=data.FTRdIP$Lat)

coordinates(pt) = ~x+y

pt2=SpatialPoints(pt)

proj4string(pt2)<- CRS("+proj=longlat +ellps=WGS84")

##### Voy a cortar un perimetro alrededor de la data, par desasirme de
las cuadrículas sin dato

##### genero el perimeto de mis observaciones

Shoot.unique=unique(data.FTRdIP[c("Lon","Lat")])

Shoot.unique<-as.matrix(Shoot.unique)

alpha=0.75 #this control how "tight" is the perimeter around the data

a.chull <- ahull(Shoot.unique,alpha=alpha)

per.lon=a.chull$arcs[,1]

per.lat=a.chull$arcs[,2]

#####

#### esto es par mirar el perimetro y tus datos

plot(per.lon,per.lat,type="l")
```

```
points(data.FTRdIP$Lon,data.FTRdIP$Lat,col="blue")
```

```
# esto es para darle coordenadas de mapa al perimetro
```

```
crds <- cbind(x=per.lon,y=per.lat)
```

```
str(crds)
```

```
PI <- Polygon(crds)
```

```
str(PI)
```

```
ID <- "a.chull"
```

```
PIs <- Polygons(list(PI), ID=ID)
```

```
str(PIs)
```

```
SPIs <- SpatialPolygons(list(PIs))
```

```
str(SPIs)
```

```
df <- data.frame(value=1, row.names=ID)
```

```
str(df)
```

```
perim <- SpatialPolygonsDataFrame(SPIs, df)
```

```
str(perim)
```

```
##### Ahora extraemos solo las cuadruculas dentro del perimetro
```

```
poly.t<-spol@polygons

s.data=length(poly.t) #Esta es la dimension de tu grilla original

med.lon=NULL

med.lat=NULL

for(i in 1:s.data){

  med.lon[i]=poly.t[[i]]@labpt[1]

  med.lat[i]=poly.t[[i]]@labpt[2]

}

med.points<-data.frame(lon=med.lon,lat=med.lat)

##### Asignando estructura a los puntos medios dentro de cada cuadrícula

med.pt=data.frame(x=med.points$lon,y=med.points$lat)

coordinates(med.pt) = ~x+y

med.pt2=SpatialPoints(med.pt)

proj4string(med.pt2)<- CRS("+proj=longlat +ellps=WGS84")

proj4string(perim) <- proj4string(med.pt2)
```

```
##### Cuales son las cuadrículas dentro de mi perimetro
```

```
win <- gWithin(med.pt2, perim, byid=TRUE)
```

```
ind.win=which(win=="TRUE")
```

```
med.points.cut=med.points[ind.win,]
```

```
##### adicionando estructura de mapa
```

```
med.cut.coor=data.frame(x=med.points.cut$lon,y=med.points.cut$lat)
```

```
coordinates(med.cut.coor) = ~x+y
```

```
med.cut.coor2=SpatialPoints(med.cut.coor)
```

```
proj4string(med.cut.coor2)<- CRS("+proj=longlat +ellps=WGS84")
```

```
##### cortando las cuadrículas dentro de mi perimetro
```

```
ind.cut<-over(med.cut.coor2,spol)
```

```
ind.cut=unique(ind.cut)
```

```
poly.win<-spol@polygons[ind.cut]
```

```
polygon.win<-SpatialPolygons(poly.win)
```

```
proj4string(polygon.win)<- CRS("+proj=longlat +ellps=WGS84")
```

```
##### un plot para mirar las cuadruculas y tus datos
```

```
plot(polygon.win)
```

```
points(data.FTRdIP$Lon,data.FTRdIP$Lat,col="red")
```

```
##### indice para asignar a que cuadrucula pertenece cada una de mis  
observaciones
```

```
ind.corr<-over(pt2,polygon.win)
```

```
#rescantando el identificador de cuadrucula
```

```
ID.pol=NULL
```

```
for(i in 1:length(ind.corr)){
```

```
  ID.pol[i]=polygon.win@polygons[[ind.corr[i]]]@ID
```

```
}
```

```
n_cuad=dim(med.points.cut)[1] # es el numero de cuadruculas dentro de mi perimetro
```

```
ID.pol.tot=NULL
```

```
med.lon2=NULL
```

```
med.lat2=NULL
```

```
for(i in 1:n_cuad){
```

```
ID.pol.tot[i]=polygon.win@polygons[[i]]@ID  
med.lon2[i]=polygon.win@polygons[[i]]@labpt[1]  
med.lat2[i]=polygon.win@polygons[[i]]@labpt[2]  
}
```

```
# Nuevo set de datos donde la variable respuesta es NA
```

```
sq=seq(1,n_cuad,1)
```

```
RFL=rep(NA,n_cuad) #variable respuesta
```

```
Year2=rep(NA,n_cuad)
```

```
Mes2=rep(NA,n_cuad)
```

```
Fecha2=rep(NA,n_cuad)
```

```
ID_FRENTE2=rep(NA,n_cuad)
```

```
#Marea_Col2=rep(NA,n_cuad)
```

```
#DirV_Col2=rep(NA,n_cuad)
```

```
#IntV_Col2=rep(NA,n_cuad)
```

```
Marea_Mdo2=rep(NA,n_cuad)
```

```
DirV_Mel2=rep(NA,n_cuad)
```

```
IntV_Mel2=rep(NA,n_cuad)
```

```
Q_RdIP2=rep(NA,n_cuad)
```

```
source2=rep("predict",n_cuad)
```

```
#data.pred=data.frame(Year=Year2,      Mes=Mes2,      Fecha=Fecha2,      RFL=NA,  
ID_FRENTE=ID_FRENTE2,Lon=med.lon2,  
Lat=med.lat2,Marea_Mdo=Marea_Mdo2,ind.corr=sq,ID=ID.pol.tot)
```

```
data.pred=data.frame(Year=Year2,      Mes=Mes2,      Fecha=Fecha2,      RFL=NA,  
ID_FRENTE=ID_FRENTE2,Lon=med.lon2,  Lat=med.lat2,  Marea_Mdo=Marea_Mdo2,  
DirV_Mel=DirV_Mel2,  
IntV_Mel=IntV_Mel2,source=source2,Q_RdIP=Q_RdIP2,ind.corr=sq,ID=ID.pol.tot)
```

```
data.FTRdIP$ind.corr<-ind.corr
```

```
data.FTRdIP$ID<-ID.pol
```

```
# juntando las dos bases de datos, observada y predicha
```

```
data.tot=rbind(data.FTRdIP, data.pred)
```

```
##### making "year2" with correlative years (allow to work with grouping
data in INLA)

data.tot$Mes2=NA

ye=sort(unique(data.tot$Mes))

for(i in 1:length(ye)){

  ind=which(data.tot$Mes==ye[i])

  data.tot$Mes2[ind]=i

}

#### dejando 3 anhos de la serie

ind.y=which(data.tot$Mes2<=3)

data.tot2=data.tot[ind.y,]

# generamos una estructura de vecindario

poly.nb <- poly2nb(polygon.win) #neighbours structure

##### plotting nb structure

nb2INLA("LDN.graph", poly.nb)
```

```
LDN.adj <- paste(getwd(),"LDN.graph",sep="")
```

```
H <- inla.read.graph(filename="LDN.graph")
```

```
image(inla.graph2matrix(H),xlab="",ylab="")
```

```
#Análisis diagnóstico para establecer correlación entre variables explicativas
```

```
DirV_Col <-data.FTRdIP$DirV_Col
```

```
IntV_Col<-data.FTRdIP$IntV_Col
```

```
DirV_Mel<-data.FTRdIP$DirV_Mel
```

```
IntV_Mel<-data.FTRdIP$IntV_Mel
```

```
Marea_Col<-data.FTRdIP$Marea_Col
```

```
Marea_Mdo<-data.FTRdIP$Marea_Mdo
```

```
Q_RdIP<-data.FTRdIP$Q_RdIP
```

```
#Anilisis diagnostico para establecer correlacion entre variables explicativas
```

```
cor.test(DirV_Col,IntV_Col, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(DirV_Mel,IntV_Mel, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(DirV_Mel,Q_RdIP, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(IntV_Mel,Q_RdIP, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(Marea_Mdo,DirV_Mel, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(Marea_Mdo,IntV_Mel, method = c("pearson", "kendall", "spearman"))
```

```
cor.test(Marea_Mdo,Q_RdIP, method = c("pearson", "kendall", "spearman"))
```

```
#####
```

```
#Modelo GAM aplicado como diagnostico para priorizar la elecci?n de variables  
explicativas
```

```
#####haciendo INLA
```

```
# esta es la formula o descripcion del modelo 1. Aqui asumimos un modelo espacial
```

usando un Markov random field (Besag) para las cuadrículas

```
form1<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)
```

esta es la formula o descripcion del modelo 2. Aqui asumimos un random walk (RW2) para intensidad y direcci?n del viento en Mdeo (es una forma de hacer smoothing) y un Markov random field (Besag) para las cuadrículas

```
#form2<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(Q_RdIP,model="iid")+f(DirV_Mel,model="iid")
```

```
form2<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(DirV_Mel,model="rw2")
```

```
form3<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(IntV_Mel,model="rw2")
```

```
form4<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(Q_RdIP,model="rw2")
```

```
form5<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(Marea_Mdo,model="rw2")
```

esta es la formula o descripcion del modelo 3. Aqui asumimos un random walk (RW2) para intensidad y direcci?n del viento en Colonia (es una forma de hacer smoothing) y un Markov random field (Besag) para las cuadrículas

```
form6<- RFL~ f(ind.corr, model = "besag", graph = LDN.adj)+f(IntV_Mel,model="rw2")+f(Q_RdIP,model="rw2")
```

```
form7<- RFL~ f(ind.corr, model = "besag", graph =
```

LDN.adj)+f(DirV_Mel,model="rw2")+f(Q_RdIP,model="rw2")

form8<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(Marea_Mdo,model="rw2")+f(Q_RdIP,model="rw2")

form9<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(IntV_Mel,model="rw2")+f(Marea_Mdo,model="rw2")

form10<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(DirV_Mel,model="rw2")+f(Marea_Mdo,model="rw2")

form16<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(DirV_Mel,model="rw2")+f(IntV_Mel,model="rw2")

form11<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(Q_RdIP,model="rw2")+f(DirV_Mel,model="rw2")+f(Marea_Mdo,model="rw2")

form12<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(IntV_Mel,model="rw2")+f(DirV_Mel,model="rw2")+f(Marea_Mdo,model="rw2"

)

form13<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(Q_RdIP,model="rw2")+f(DirV_Mel,model="rw2")+f(IntV_Mel,model="rw2")

form15<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(Q_RdIP,model="rw2")+f(IntV_Mel,model="rw2")+f(Marea_Mdo,model="rw2")

form14<- RFL~ f(ind.corr, model = "besag", graph =

LDN.adj)+f(IntV_Mel,model="rw2")+f(DirV_Mel,model="rw2")+f(Marea_Mdo,model="rw2")

```
)+f(Q_RdIP,model="rw2")
```

```
# esta de abajo es la que ejecuta la formulacion del modelo
```

```
m1 <- inla(form1,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
,verbose=TRUE)
```

```
m = get("inla.models", INLA:::inla.get.inlaEnv())
```

```
m$latent$rw2$min.diff = NULL
```

```
assign("inla.models", m, INLA:::inla.get.inlaEnv())
```

```
m2 <- inla(form2,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
,verbose=TRUE)
```

```
m = get("inla.models", INLA:::inla.get.inlaEnv())
```

```
m$latent$rw2$min.diff = NULL
```

```
assign("inla.models", m, INLA:::inla.get.inlaEnv())
```

```
m3 <- inla(form3,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m4 <- inla(form4,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m5 <- inla(form5,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m6 <- inla(form6,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m7 <- inla(form7,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m8 <- inla(form8,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m9 <- inla(form9,family="gaussian", data = data.tot, control.predictor = list(compute =  
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)

m10 <- inla(form10,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m11 <- inla(form11,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m12 <- inla(form12,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m13 <- inla(form13,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m14 <- inla(form14,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m15 <- inla(form15,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),

,verbose=TRUE)

m16 <- inla(form16,family="gaussian", data = data.tot, control.predictor = list(compute =
TRUE),control.compute=list(dic=TRUE,waic=TRUE),
```

```
,verbose=TRUE)
```

```
m = get("inla.models", INLA:::inla.get.inlaEnv())
```

```
m$latent$rw2$min.diff = NULL
```

```
assign("inla.models", m, INLA:::inla.get.inlaEnv())
```

```
m1$dic$dic
```

```
m2$dic$dic
```

```
m3$dic$dic
```

```
m4$dic$dic
```

```
m5$dic$dic
```

```
m6$dic$dic
```

```
m7$dic$dic
```

```
m8$dic$dic
```

```
m9$dic$dic
```

```
m10$dic$dic
```

```
m16$dic$dic
```

```
m11$dic$dic
```

```
m12$dic$dic
```

```
m13$dic$dic
```

```
m15$dic$dic
```

```
m14$dic$dic
```

```
dic1 <- m1$dic$dic
```

```
dic2 <- m5$dic$dic
```

```
dic_diff <- dic1 - dic2
```

```
dic_diff_sd <- sqrt(m1$dic$dic.se^2 + m5$dic$dic.se^2)
```

```
# Imprimir los resultados
```

```
cat("El valor de DIC para el primer modelo es", round(dic1, 2), "\n")
```

```
cat("El valor de DIC para el segundo modelo es", round(dic2, 2), "\n")
```

```
cat("La diferencia en los valores de DIC es", round(dic_diff, 2), "+/-", round(dic_diff_sd, 2),  
"\n")
```

```
# Definir los valores de DIC de los dos modelos
```

```
# Calcular la diferencia en los valores de DIC
```

```
dic_diff <- dic2 - dic1
```

```
# Calcular la desviación estándar de la diferencia

#dic_diff_sd <- sqrt(var(c(dic1, dic2)))

# Calcular el valor-z

z_score <- dic_diff / dic_diff_sd

# Calcular el valor p (dos colas)

p_value <- 2 * pnorm(-abs(z_score))

#####

#####

m1.fit=m1$summary.fitted[, "mean"] # rescantando la media de las predicciones

m2.fit=m2$summary.fitted[, "mean"] # rescantando la media de las predicciones

m3.fit=m3$summary.fitted[, "mean"] # rescantando la media de las predicciones

m4.fit=m4$summary.fitted[, "mean"]
```

```
m5.fit=m5$summary.fitted[, "mean"]
```

```
m6.fit=m6$summary.fitted[, "mean"]# rescantando la media de las predicciones
```

```
m7.fit=m7$summary.fitted[, "mean"] # rescantando la media de las predicciones
```

```
m8.fit=m8$summary.fitted[, "mean"] # rescantando la media de las predicciones
```

```
m9.fit=m9$summary.fitted[, "mean"] # rescantando la media de las predicciones
```

```
m10.fit=m10$summary.fitted[, "mean"]
```

```
m11.fit=m11$summary.fitted[, "mean"]
```

```
m12.fit=m12$summary.fitted[, "mean"] # rescantando la media de las predicciones
```

```
m13.fit=m13$summary.fitted[, "mean"] # rescantando la media de las predicciones
```

```
m14.fit=m14$summary.fitted[, "mean"]
```

```
m15.fit=m15$summary.fitted[, "mean"]

m16.fit=m16$summary.fitted[, "mean"]

# rescantando la media de las predicciones

#####

#####

#### para plotear un mapa de las predicciones espaciales

scale = list("SpatialPolygonsRescale", layout.scale.bar(),

            offset = c(600000,9700000), scale = 50000, fill=c("transparent","black"))

text1 = list("sp.text", c(600000,9709000), "0")

text2 = list("sp.text", c(650000,9709000), "50 km")

#Flecha de norte.

arrow = list("SpatialPolygonsRescale", layout.north.arrow(),

            offset = c(620000,9715000), scale = 30000)

write.csv(data.plot, "mi_plotv2.csv")

#####

#####
```

```
#### para plotear un mapa de las predicciones espacio-temporales

ind2=which(data.tot$source=="predict")

data.plot=data.frame(ind.corr=data.tot$ind.corr[ind2], RFL=m15.fit[ind2])

row.names(data.plot)<-data.tot$ID[ind2]

polygons <- SpatialPolygonsDataFrame(polygon.win, data.plot)

CAL.POL <- list("sp.polygons", mapa, lwd=1,fill="grey",first=FALSE)

z1<-spplot(polygons, c("RFL"),col.regions = rev(heat_hcl(55, c = c(90,40), l = c(40, 90),
power = c(1/5, 1.3))),sp.layout=list(CAL.POL,scale,text1,text2,arrow),col = NA,
scales=list(draw=T),las=2,main="La Niña 3 meses mQMVv" ,

      at=seq(0.02,0.16,by=0.005),

      colorkey=list(labels=list(labels=seq(0.02,0.16,by=0.005),

      at=seq(0.02,0.16,by=0.005),

      width=10, cex=0.5)))

jpeg(file = "Figure La Niño 4 meses m15.jpg", width = 3000, height = 1500, units = "px",
res = 300)

plot(z1)

dev.off()

plot(z1)

write.csv(data.plot, "plot_ninho_4meses_m15_v2.csv")
```

