

**Universidade Federal do Rio Grande**

**Instituto de Oceanografia**

Programa de Pós-Graduação em Oceanologia

**Caracterização ótica e quantificação do material particulado em suspensão do estuário e da pluma da Lagoa dos Patos (RS, Brasil) por sensoriamento remoto.**

**Luiza Luz Sartorato**

Dissertação apresentada ao Programa de Pós-Graduação em Oceanologia, como parte dos requisitos para a obtenção do Título de Mestre

Orientador: *Prof. Dr.* Carlos Alberto Eiras Garcia

Rio Grande, RS, Brasil

Maio de 2020

# **Caracterização ótica e quantificação do material particulado em suspensão do estuário e da pluma da Lagoa dos Patos (RS, Brasil) por sensoriamento remoto.**

Dissertação apresentada ao Programa de Pós-Graduação em Oceanologia, como parte dos requisitos para a obtenção do Título de Mestre

por

**Luiza Luz Sartorato**

Rio Grande, RS, Brasil  
Maio 2020

© A cópia parcial e a citação de trechos desta tese são permitidas sobre a condição de que qualquer pessoa que a consulte reconheça os direitos autorais do autor. Nenhuma informação derivada direta ou indiretamente desta obra deve ser publicada sem o consentimento prévio e por escrito do autor

Sartorato, Luiza Luz

Caracterização ótica e quantificação do material particulado em suspensão do estuário e da pluma da Lagoa dos Patos (RS, Brasil) por sensoriamento remoto. / Luiza Luz Sartorato – Rio Grande: FURG, 2020.

Número de páginas p. 104

Dissertação (Mestrado) – Universidade Federal do Rio Grande.

Mestrado em Oceanologia. Área de Concentração: Física dos Oceanos e Clima. 1. Material total em suspensão. 2. Sensoriamento remoto. 3. Correção atmosférica. 4. Constituintes e propriedades ópticas. I. Caracterização ótica e quantificação do material particulado em suspensão do estuário e da pluma da Lagoa dos Patos (RS, Brasil) por sensoriamento remoto.



## ATA ESPECIAL DE DEFESA DE DISSERTAÇÃO DE MESTRADO – 05/2020

Às 9h do dia 18 de maio do ano de dois mil e vinte, por videoconferência, reuniu-se a Comissão Examinadora da Dissertação de **MESTRADO** intitulada "**Caracterização ótica e quantificação do material particulado em suspensão do estuário e da pluma da Lagoa dos Patos (RS, Brasil) por sensoriamento remoto**", da **Acad. Luiza Luz Sartorato**. A Comissão Examinadora foi composta pelos seguintes membros: Prof. Dr. Carlos Alberto Eiras Garcia – (Orientador– IO-FURG), Prof. Dr. Jorge Arigony Neto (IO-FURG), Profa. Dra. Maria Fernanda Giannini (IO/FURG) e Profa. Dra. Ana Dogliotti (CONICET-Argentina). Dando início à reunião, o Presidente da Sessão, Prof. Dr. Carlos Garcia, agradeceu a presença de todos, e fez a apresentação da Comissão Examinadora. Logo após, esclareceu que a Candidata teria de 45 a 60 min para explanação do tema, e cada membro da Comissão Examinadora, um tempo máximo de 30 min para perguntas. A seguir, passou à palavra a Candidata, que apresentou o tema e respondeu às perguntas formuladas. Após ampla explanação, a Comissão Examinadora reuniu-se em reservado para discussão do conceito a ser atribuído a Candidata. Foi estabelecido que as sugestões de todos os membros da Comissão Examinadora, que seguem em pareceres em anexo, foram aceitas pelo Orientador/Candidata para incorporação na versão final da Dissertação. Finalmente, a Comissão Examinadora considerou a candidata aprovada por unanimidade. Nada mais havendo a tratar, foi lavrada a presente ATA, que após lida e aprovada, será assinada pela Comissão Examinadora, pelo Candidato e pelo Coordenador o Programa de Pós-Graduação em Oceanologia (PPGO).

Prof. Dr. Carlos Alberto Eiras Garcia  
Presidente

Profa. Dra. Maria Fernanda Giannini

Profa. Dra. Ana Dogliotti

Prof. Dr. Jorge Arigony Neto

Acad. Luiza Luz Sartorato

Prof. Dr. Rodrigo Kerr  
Coordenador do PPGO

# Agradecimentos

Agradeço, antes de tudo, à minha família por todo suporte, força e base que sempre me foi dado. Sem vocês nada do que eu conquistei até agora seria possível. Como uma amiga me disse um dia: “vocês são os verdadeiros financiadores da ciência no Brasil”.

Dedico este trabalho e todo meu amor a vocês: mãe, pai e Thiago.

Agradeço meus avós, Telmo e Rosa, por todo apoio e carinho. Minhas incessáveis fontes de inspiração e amor.

Agradeço ao meu segundo pai, Ivan, também pelo seu suporte e amor. Obrigada por tudo que sempre fez e faz por mim. Afinal, você quem (literalmente) me trouxe aqui. Amo você!

Agradeço ao Felipe por todo amor, confiança e carinho. Obrigada por me amparar em todas as incontáveis situações que eu estava perdida. Te amo.

Agradeço ao meu orientador, Carlos, pela paciência e confiança, mesmo quando eu não era merecedora de tanto.

Agradeço profundamente aos meus amigos, a todos que fiz em cada canto do Brasil e do mundo. Por todos os bons momentos e alegrias que dividiram comigo.

Gostaria de agradecer também ao Sistema de Monitoramento da Costa do Brasil (SiMCosta) e a toda equipe que o compõe. Obrigada por toda ajuda e suporte que vocês sempre me deram.

Agradeço à FURG, ao Instituto Oceanográfico e ao CEOCEAN pela infraestrutura onde o trabalho foi realizado.

E por fim, ao Programa de Pós-Graduação em Oceanologia e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pela oportunidade e financiamento que me foram concebidos.

# Índice

Agradecimentos.....	I
Lista de Figuras da Dissertação.....	V
Lista de Figuras do Artigo.....	VII
Lista de Tabelas da Dissertação.....	X
Lista de Tabelas do Artigo.....	XI
Lista de Acrônimos e Abreviações.....	XII
Resumo.....	XIV
Abstract.....	XVI
Capítulo I: Introdução.....	1
I.1. Propriedades ópticas dos oceanos.....	7
I.2. Constituintes opticamente ativos presentes na água.....	8
I.3. “Cor dos oceanos” estimada via sensoriamento remoto aqua.....	11
I.3.1. Correção atmosférica.....	13
Capítulo II: Objetivos.....	15
II.1. Geral.....	15
II.2. Específicos.....	15
Capítulo III: Área de Estudo.....	17
Capítulo IV: Materiais e Métodos.....	20
IV.1. Delineamento amostral e medidas coletadas <i>in situ</i> .....	20

IV.1.1. Medidas das propriedades óticas inerentes (IOPs) e dos constituintes opticamente ativos.....	21
IV.1.2. Medidas radiométricas hiper-espectrais sobre a água.....	23
IV.1.3. Medição do material particulado total em suspensão (TSM).....	25
IV.1.4. Abordagem estatística utilizada para análise das observações <i>in situ</i> .....	25
IV.2. Aquisição e processamento dos dados de sensoriamento remoto.....	26
IV.2.1. Aplicação das correções atmosféricas.....	27
IV.2.2. Procedimentos de <i>match-up</i> .....	29
IV.3. Desenvolvimento e avaliação dos modelos de TSM.....	30
IV.4. Validação dos algoritmos resultantes de TSM.....	34
Capítulo V: Artigo Científico.....	35
1. Introduction.....	37
2. Study Area.....	39
3. Methods.....	42
3.1. Field Campaigns and <i>in situ</i> measurements.....	42
3.1.1. Measurements of inherent optical properties and active optical constituents.....	42
3.1.2. Above-water hyperspectral radiometric measurements.....	43
3.2. Statistical analysis for the <i>in situ</i> observations.....	44
3.3. Remotely sensed data acquisition and processing.....	45
3.3.1. Atmospheric Corrections.....	45

3.3.2. Match-up exercises.....	46
3.4. TSM Model Development and Assessment.....	47
3.5. Validation of the resulting TSM algorithm.....	49
4. Results and Discussion.....	50
4.1. Optical complexity and variability in the EPL.....	50
4.2. Validation of Atmospheric Corrections.....	56
4.3. TSM model's assessment.....	59
5. Concluding remarks.....	68
6. Supplementary Materials.....	73
Capítulo VII: Síntese da Discussão e Conclusões.....	74
Referências Bibliográficas.....	82



# Lista de Figuras da Dissertação

- Figura 1.** Espectros de reflectância por sensoriamento remoto ( $R_{rs}(\lambda)$ ) de diferentes tipos de águas: (a) águas com concentrações de CDOM e TSM muito elevadas, (b) altas concentrações CDOM e TSM, (c) concentrações CDOM e TSM moderadas com fitoplâncton, (d) água clara, (e) águas com concentrações de CHLa e de TSM moderados, (f) águas com concentração de CHLa moderada. a, b, c e e são Águas Caso II; d e f são Águas Caso I. Figura adaptada do 3º relatório do IOCCG (2000).....4
- Figura 2.** Coeficiente de absorção da água do mar e seus principais constituintes.  $a_w$ = coeficiente de absorção da água pura,  $a_{CDOM}$ = coeficiente de absorção do CDOM,  $a_{ph}$ = coeficientes de absorção do fitoplâncton (CHLa),  $a_{NAP}$ = coeficientes de absorção das partículas não-algais e  $a_{tot}$ = somatório de todos os coeficientes de absorção. Figura modificada de Kratzer & Kowalczyk (2017).....10
- Figura 3.** Localização da Lagoa dos Patos e da sua porção estuarina ao Sul.....19
- Figura 4.** Localização das estações, diferenciadas pelos anos de amostragem. Os quadrados verdes representam os pontos coletados nos anos de 2014 e 2015, os triângulos azuis são referentes às estações coletadas em 2016, e os símbolos de adição laranjas são do período 2018-2019.....21
- Figura 5.** Equipamentos utilizados para a aquisição das propriedades e constituintes ópticos. Equipamentos da Seabird e WetLabs utilizados para as medidas de IOPs, condutividade, temperatura e pressão. acoplados à estrutura

metálica (a); o radiômetro HyperSAS posicionado na casaria da embarcação,  
utilizado para a aquisição das AOPs (b).....23

# Lista de Figuras do Artigo

**Figure 1.** Study area and location of sampled stations. The squares represent the stations collected in 2014-2015, the triangles represent the stations collected in 2016 and the plus signs the stations collected in 2018-2019.....41

**Figure 2.** Cluster K-means analysis over each *in situ* spectra collected (a) and the average normalized reflectance of each class (b).....53

**Figure 3.** PCA showing the total variance of  $\rho$  described by the optical constitution of the samples. Large size markers represent the mean point of each class.....54

**Figure 4.** (a) The statistical metrics (R-squared, MAPE, and Bias), the solid line represents the R-squared, the dashed line refers to the Bias, and the dotted line refers to the MAPE. (b) The TSM concentration for each individual spectrum collected on field for each linear regressions performed between TSM concentration and  $\rho$  in 137 bands. The vertical lines correspond to each center-band analyzed in this study for algorithms development –  $\rho(645)$ ,  $\rho(671)$ , and  $\rho(745)$ .....55

**Figure 5.** Linear regressions between *in situ* and the satellite-derived  $\rho$ . The first column (a,e,i) represents  $\rho$  derived using the standard NIR correction algorithm, the second (b,f,j) using the adapted NIR-SWIR, the third (c,g,k) using the MUMM correction, and the fourth (d,h,l), the standard NIR-SWIR. First row (a,b,c,d) corresponds to the MODIS-derived  $\rho(645)$ , the second (e,f,g,h) corresponds to the

VIIRS-derived  $\rho(671)$ , and the third (i,j,k,l) to the VIIRS-derived  $\rho(745)$ . The dashed line refers to 1:1 and the thick black line to linear fitting.....57

**Figure 6.** Red-to-NIR band comparison between *in situ* data from 2018-2019 campaigns (black dots) and VIIRS-derived  $\rho$  from all the scenes (colored dots), the black solid line corresponds to the *in situ* logarithmic fit function, and the dashed lines to the 95% confidence level curves. The (a) first column represents  $\rho$  derived using the standard NIR correction algorithm, (b) the second using the adapted NIR-SWIR, (c) the third using the MUMM correction, and (d) the fourth, the standard NIR-SWIR.....58

**Figure 7.** (a) Scatter plots of the convoluted  $\rho(\text{red})$  versus TSM concentration. Red dots represent the *in situ* weighted  $\rho(645)$ , and green dots the  $\rho(671)$ . (b) Scatter plot of the convoluted  $\rho(745)$  versus TSM concentration. The solid lines represent the polynomial and linear best fits for each band. See Table 4 for details.....60

**Figure 8.** Satellite-derived versus *in situ* TSM concentrations. The first column (a,e,i) represents the TSM concentrations estimated from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR products, the third (c,g,k) using the MUMM derived  $\rho$ , and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to MODIS-derived  $\rho(645)$ , the second (e,f,g,h) to VIIRS-derived  $\rho(671)$ , and the third (i,j,k,l) to VIIRS-derived  $\rho(745)$ .....63

**Figure 9.** TSM maps estimated from MODIS and VIIRS products. The first column (a,e,i) represents the products from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR model, the third (c,g,k), the MUMM correction,

and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to TSM maps estimated using the polynomial algorithm for MODIS-derived  $\rho(645)$ , the second (e,f,g,h), using the polynomial model for VIIRS-derived  $\rho(671)$ , and the third (i,j,k,l) using the linear model using VIIRS-derived  $\rho(745)$ . The scenes were acquired on 17 August 2019. The image on the right corresponds to the MODIS true-color composite scene acquired on the same day. The white dot on the image represents a TSM measurement collected by  $\pm 1$  hour from sensor overpass (20mg/L).....65

**Figure 10.** TSM maps computed by the transitional algorithm (Novoa et al., 2017) applied to VIIRS-derived products. The first column (a) represents the TSM maps estimated from standard NIR corrected products, the second (b) using the modified NIR-SWIR products, the third (c) using the MUMM derived  $\rho$ , and (d) the fourth, the standard NIR-SWIR.....67

**Figure 11.** TSM maps estimated from VIIRS products. The first column (a,e,i) represents the TSM maps estimated from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR products, the third (c,g,k) using the MUMM derived  $\rho$ , and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to TSM maps estimated using the polynomial red algorithm for VIIRS-derived  $\rho(671)$ , the second (e,f,g,h) to TSM maps estimated using the linear red model for VIIRS-derived  $\rho(745)$ , and the third (i,j,k,l) to concentrations calculated via the transitional model.....68

# Lista de Tabelas da Dissertação

<b>Tabela 1.</b> Data, número de observações usadas para calibrar e validar o algoritmo de TSM e variações da concentração de TSM em cada campanha.....	22
---	----

# Lista de Tabelas do Artigo

<b>Table 1.</b> Date, number of observations used to calibrate and validate the TSM algorithm, and TSM concentration ranges of each campaign.....	40
<b>Table 2.</b> Mean, standard deviation, maximum, and minimum values of the physical variables, IOPs and active optical constituents with their respective units. Results are also divided in subregions: inner and outer lagoon. The mouth of the channel (Figure 1) was defined as the limit of the lagoon. All variables, include values in the water column, except TSM which was measured only at surface.....	50
<b>Table 3.</b> Pearson Correlation analysis between the IOPs, the optically active constituents and conservative properties of the entire water column (p-value<0.5). The values highlighted are the greatest encountered for each column.....	51
<b>Table 4.</b> R-squared, mean absolute percentage error, root mean squared error, and bias computed from the regressions between the <i>in situ</i> $\rho$ convoluted to MODIS and VIIRS bands and the TSM concentrations. The resulting model from each fit is elucidated.....	61
<b>Table 5.</b> R-squared, mean absolute percentage error, root mean squared error, and bias computed from the comparison of <i>in situ</i> , VIIRS/SNPP-derived TSM, and the recalibrated Nechad et al. (2010)-derived TSM. The metrics are calculated for all atmospheric corrections. The first four columns correspond to the proposed polynomial and linear models for calculating TSM concentration, the last four columns represent Nechad et al. (2010) models.....	64

# Lista de Acrônimos e Abreviações

## A

**AOP** – Propriedade óptica aparente (*Apparent optical property*)

**a** – Coeficiente de absorção ( $m^{-1}$ )

## B

**b** – Coeficiente de espalhamento ( $m^{-1}$ )

## C

**CDOM** – Matéria orgânica dissolvida colorida (*Chromophoric dissolved organic matter*)

**CHLa** – Clorofila-a (*Chlorophyll-a*)

**CV** – Coeficiente de Variação

**CZCS** – *Coastal Zone Color Scanner*

**c** – Coeficiente de atenuação (*Beam attenuation coefficient*)

## H

**HyperSAS** – *Hyperspectral Surface Acquisition System*

## I

**IOP** – Propriedade óptica inerente (*inherent optical property*)

## M

**MAPE** – Erro médio absoluto percentual (*mean absolute percentage error*)

**MODIS** – *Moderate Resolution Imaging Spectroradiometer*

**MSI** – *Multispectral Instrument*

**MUMM** – *Management Unit of the North Sea Mathematical Models*

## N

**NAP** – Partículas não-algais (*non-algal particles*)

**NIR** – Infravermelho próximo (*near-infrared*)

**NPP** – *National Polar-orbiting Partnership*



## O

**OCSSW** – *OceanColor Science Software*

**OLCI** – *Ocean and Land Colour Instrument*

**OLI** – *Operational Land Imager*

## S

**SeaDAS** – *SeaWiFS Data Analysis System*

**SeaWiFS** – *Sea-viewing Wide Field-of-view Sensor*

**SWIR** – *Infravermelho de ondas curtas (Short wave infrared)*

## P

**PLE** – *Estuário da Lagoa dos Patos (Patos Lagoon estuary)*

## T

**TSM** – *Material total particulado em suspensão (Total suspended matter)*

## R

**RMSE** – *Raiz do erro quadrático médio (Root mean square error)*

**RTE** – *Equação da transferência radiativa (Radiative Transfer Equation)*

**R<sup>2</sup>** – *Coeficiente de determinação ou R-quadrado (Coefficient of determination or R-squared)*

**Rrs** – *Reflectância por sensoriamento remoto (Remote Sensing Reflectance)*

## V

**VIIRS** – *Visible Infrared Imaging Radiometer Suite*

## Símbolos

**$\lambda$**  – *Comprimento de onda (Wavelength)*  
(nm)

**$\rho(\lambda)$**  – *Reflectância “saindo da água” (Water-leaving reflectance) (sr<sup>-1</sup>)*

# Resumo

A preocupação com os ambientes marinhos é hoje uma questão global e a concentração total de material em suspensão (TSM) tornou-se um proxy da qualidade das águas costeiras. Dessa forma, o sensoriamento remoto surge como uma potencial ferramenta para estimar indiretamente as concentrações de TSM e monitorar grandes áreas sinopticamente. Assim, correções atmosféricas apropriadas são frequentemente necessárias. O presente trabalho tem como objetivos identificar padrões de variabilidade de propriedades ópticas em uma lagoa costeira no Brasil e oceano adjacente, avaliar a performance de quatro correções atmosféricas e criar um modelo empírico preciso para estimar a concentração de TSM a partir de dados dos sensores MODIS-Aqua (250 m) e VIIRS-SNPP (750-m). Inúmeras campanhas ocorreram de 2014 a 2019, quando foram coletados dados de propriedades ópticas e constituintes ópticos da região. As correções atmosféricas aplicadas às imagens foram: a correção NIR padrão, dois algoritmos de comutação NIR-SWIR e a correção MUMM. Duas bandas nos intervalos espectrais do vermelho e infravermelho próximo (NIR) foram escolhidas para estimar a concentração de TSM. Os resultados demonstraram que as águas da Lagoa de Patos apresentam codominância entre CDOM e TSM em sua composição óptica, o que influencia fortemente a variabilidade das refletâncias emitidas pelos corpos aquosos. Os algoritmos de correção atmosférica NIR-SWIR apresentaram os melhores resultados. Como resultado final, três algoritmos de cálculo da concentração de TSM foram construídos com base nas bandas dos sensores MODIS e VIIRS –  $\rho(645)$ ,  $\rho(671)$  e  $\rho(745)$ . O desempenho de cada modelo foi satisfatório e representou bem a dinâmica das concentrações de TSM. Além disso, um algoritmo de transição entre as bandas 671 e 745 foi adaptado para estimar a concentração de TSM quando fortes gradientes eram formados na área interna da laguna para regiões adjacentes.

**Palavras-chave:** Material total em suspensão, sensoriamento remoto, correção atmosférica, complexidade óptica, constituintes e propriedades ópticas.

# Abstract

The concern regarding the health of marine environments is a global issue, and total suspended matter (TSM) concentration is one great proxy for coastal water quality. Then, the passive remote sensing arises as a tool for estimating TSM and monitoring large estuaries synoptically, where appropriate atmospheric corrections are often required. The present work aims to identify patterns of variability of optical properties in a Brazilian coastal lagoon and adjacent oceanic waters, assess four atmospheric correction schemes and create an accurate empirical model to estimate the TSM concentration from MODIS-Aqua (250-m) and VIIRS-SNPP (750-m) sensors. Field campaigns occurred from 2014 to 2019, when optical properties and constituents were collected. The standard iterative NIR, two NIR-SWIR switching algorithms, and the MUMM correction were applied to the images, and two bands in red and near-infrared (NIR) intervals were chosen for estimating TSM concentration. The results demonstrated that the Patos Lagoon waters present a co-dominance between CDOM and TSM on its optical composition, which strongly influences the water-leaving reflectance variability. The NIR and NIR-SWIR based atmospheric correction algorithms presented better results for retrieving water-leaving reflectances. As a final result, three TSM algorithms have been built based on MODIS and VIIRS bands –  $\rho(645)$ ,  $\rho(671)$  and  $\rho(745)$ . The performance of each model was satisfactory and represented well the dynamics of TSM concentrations. Also, a transitional algorithm between red and NIR bands was adapted to estimate TSM when strong gradients are formed from inner to the outer lagoon.

**Keywords:** Total suspended matter, optical remote sensing, atmospheric correction, algorithms, optical complexity, active optical constituents.

# Capítulo I: Introdução

A forma como os materiais dissolvidos e particulados presentes nos oceanos interagem com a luz solar visível (400-700 nm) determina a sua coloração, que nada mais é do que o produto resultante das suas assinaturas espectrais (Stramski et al., 2004). As propriedades que regem essas interações são ditas como ópticas inerentes e aparentes. As propriedades ópticas inerentes (IOP – *Inherent Optical Properties*) são aquelas determinadas unicamente pelas características do meio, como absorção ou espalhamento, enquanto que as propriedades aparentes (AOP – *Apparent Optical Properties*) são definidas tanto pelas particularidades do meio, quanto pelo campo direcional da luz, como as radiâncias e reflectâncias (Preisendorfer, 1976).

Os principais constituintes que afetam as propriedades ópticas na água são: (1) as partículas fitoplanctônicas, (2) a matéria orgânica dissolvida colorida


(CDOM), (3) as partículas não-algais (NAP), entre as quais enquadram-se partículas inorgânicas (minerais) e orgânicas em suspensão (4) e as próprias moléculas de água (IOCCG, 2000; Mobley, 1994). Uma vez que existe grande variabilidade desses constituintes nas diferentes regiões do globo, os corpos aquosos foram descritos por Gordon e Morel (1983) em dois grandes grupos: (1) águas do Tipo I ou oceânicas, nas quais há dominância de partículas fitoplanctônicas na coluna d'água, fazendo com que as IOPs e AOPs variem proporcionalmente com a concentração de clorofila-a no ambiente. E as águas Tipo II ou complexas, onde a assinatura espectral da superfície é determinada por um ou mais constituintes opticamente ativos presentes no meio, sem que haja necessariamente correlação entre os mesmos. A Figura 1 apresenta os espectros resultantes destas classificações, demonstrando que o entendimento da complexidade óptica de cada região é essencial para compreender a sua dinâmica biogeoquímica.

As águas costeiras são geralmente enquadradas nesta segunda categoria (Tipo II) e considerando que cerca de 41% da população mundial vive até 100 km da costa (Small & Nicholls, 2003), torna-se imprescindível o monitoramento de ambientes como rios e estuários, já que os mesmos representam importantes fontes de materiais particulados e dissolvidos oriundos do continente para os oceanos (Cai, 2011). A crescente preocupação com a saúde dos ecossistemas marinhos fez com que inúmeros países definissem legislações pertinentes para a sua manutenção, como é o caso da *Marine Strategy Directive Framework* criada

pela União Europeia (Howarth, 2008), que estabelece que todas as uniões signatárias tomem as medidas necessárias para proteger e preservar os ambientes costeiros. Do mesmo modo, no Brasil, o Conselho Nacional do Meio Ambiente instituiu resoluções de classificação de balneabilidade e padronização de efluentes descartados em corpos aquosos (CONAMA, 2012). Considerando tal cenário, o material total particulado em suspensão (TSM) pode ser considerado um importante proxy da qualidade das águas costeiras, uma vez que este afeta a penetração de luz e pode limitar a produtividade primária, além de ser um potencial carreador de poluentes para os ambientes marinhos (Bilotta & Brazier, 2008; Newcombe & MacDonald, 1991; Niencheski & Baumgarten, 2000; Williamson et al., 1996).

Apesar da importância do acompanhamento contínuo desta variável em ambientes costeiros, as metodologias tradicionais de coleta da mesma, bem como o alto custo financeiro envolvido, ainda limitam a disponibilidade espaço-temporal de dados. Tal fato reforça a necessidade de um monitoramento sinóptico em extensos estuários e áreas costeiras, de forma que alguns estudos sugerem o uso de dados ópticos de sensoriamento remoto para estimar indiretamente as concentrações de TSM (Acker et al., 2005; Binding et al., 2005; Doxaran et al., 2016; Knaeps et al., 2015; Nechad et al., 2010a; Zhang et al., 2010). Após o lançamento do sensor *Coastal Zone Color Scanner* (CZCS) na década de 70, outros radiômetros foram lançados a bordo de satélites com variadas resoluções temporal, espacial e espectral criados com intuito de mensurar indiretamente

parâmetros geofísicos globais como: clorofila-a, temperatura, salinidade, carbono orgânico particulado, etc. (Gordon, 2010).



**Figura 1.** Espectros de reflectância por sensoriamento remoto ( $R_{rs}(\lambda)$ ) de diferentes tipos de águas: (a) águas com concentrações de CDOM e TSM muito elevadas, (b) altas concentrações CDOM e TSM, (c) concentrações CDOM e TSM moderadas com fitoplâncton, (d) água clara, (e) águas com concentrações de CHLa e de TSM moderados, (f) águas com concentração de CHLa moderada. a, b, c e e são Águas Caso II; d e f são Águas Caso I. Figura adaptada do 3º relatório do IOCCG (2000).

Tendo em vista que estuários são ambientes extremamente dinâmicos, a concentração das partículas suspensas pode variar significativamente em diversas escalas temporais e espaciais (e.g. de horas a semanas ou de centímetros para quilômetros). De acordo com Aurin et al. (Aurin et al., 2013), a resolução espacial ótima de um sensor necessária para resolver esta heterogeneidade em zonas costeiras é de pelo menos 630 m. Atualmente existem alguns sensores passivos em órbita com altíssimas resoluções espaciais, como é o caso do *Operational*



*Land Imager* (OLI) a bordo do satélite Landsat, que possui 30 m de resolução, e dos sensores *Ocean and Land Colour Instrument* (OLCI) e *Multispectral Instrument* (MSI) a bordo dos satélites Sentinel 3 e 2, que possuem resoluções de 300 e até 20 m, respectivamente. Contudo, o tempo de revisita destes sensores são relativamente altos, sendo que o OLI retorna ao mesmo ponto no globo após 16 dias, o OLCI retorna após 1 ou 2 dias (apresentando alguns hiatos) e o MSI após 5 dias. Essas resoluções temporais podem limitar uma descrição acurada da dinâmica de determinado ambiente, uma vez que fenômenos de alta frequência podem ser mascarados ou perdidos da cena. Assim, o *Moderate Resolution Imaging Spectroradiometer* a bordo do satélite Aqua (MODIS-Aqua) e o *Visible Infrared Imaging Radiometer* a bordo do satélite *Suomi National Polar-orbiting Partnership* (VIIRS-NPP) surgem como alternativas para mapear o TSM e vem sendo amplamente utilizados para este propósito, já que ambos possuem razoável compensação entre suas resoluções espaciais e temporais, com tempo de revisita diário, e resoluções de até 250 m (MODIS) e 750 m (VIIRS) (C. Cao et al., 2013; Z. Cao et al., 2018; Chen et al., 2007; Hlaing et al., 2013; Hu et al., 2004; Li et al., 2003; Nechad et al., 2010a).

Um dos grandes desafios contemporâneos na área do sensoriamento remoto passivo é a criação de um algoritmo global robusto o suficiente para estimar o TSM em qualquer região do planeta, e inúmeros trabalhos vem sendo feitos nas últimas décadas com este intuito (Doxaran et al., 2002; Han et al., 2016; Nechad et al., 2010b). Esses modelos são geralmente classificados como

empíricos ou semi-analíticos, sendo que os algoritmos empíricos geralmente estabelecem relações diretas entre a AOP em questão (e.g. reflectâncias, radiâncias) e a concentração do constituinte óptico de interesse usando dados coletados *in situ*. Apesar da sua simplicidade, fácil aplicação e baixo tempo computacional, esses modelos são regionalmente limitados e mais sensíveis às variações das concentrações dos constituintes opticamente ativos presentes na água. Os algoritmos semi-analíticos, por outro lado, são gerados a partir das relações entre IOPs coletadas em *in situ* e o espectro resultante de reflectância ou radiância (AOPs), bem como das equações da transferência radiativa (RTE) para resolver os fenômenos de propagação da luz na água. A partir de relações inversas resultantes deste tipo de abordagem são criados modelos capazes de estimar a concentração do constituinte desejado com base nos espectros das AOPs (Ioannou et al., 2011; IOCCG, 2000). Embora esses modelos inversos demonstrem bons resultados em regiões costeiras, sua implementação é mais complexa e geralmente requer maior tempo e performance computacional, além do fato de medidas *in situ* das IOPs serem menos frequentes.

No que concerne às águas continentais brasileiras, inúmeros algoritmos utilizando dados de sensoriamento remoto foram desenvolvidos e validados com intuito de estimar a concentração de TSM (Fassoni-Andrade & Paiva, 2019; Novo et al., 2006; Rudorff et al., 2018; Villar et al., 2012). Contudo, poucos estudos com a mesma proposta foram conduzidos com o intuito no estuário da Lagoa dos Patos (Costi et al., 2017; Pagot et al., 2007; Tavora et al., 2019). Sendo que em nenhum

destes trabalhos foram feitas medidas das propriedades óticas do ambiente. Assim, o presente trabalho busca, então, preencher as lacunas de conhecimento ainda remanescentes nesta região.

### **I.1. Propriedades óticas dos oceanos**

Como foi dito anteriormente, as propriedades óticas inerentes são determinadas unicamente pelas características físicas do meio, como a forma, tamanho, tipo de material ou concentração das partículas nele inseridas, independente da configuração geométrica do campo de luz. Ou seja, não variam quando a posição do Sol muda ao longo do dia (Mobley, 1994).

Uma vez que os fótons interagem com a matéria, certos fenômenos podem ocorrer dependendo dessas características inerentes do meio, como a absorção, o espalhamento, ou a transmissão da luz solar. Estes fenômenos descrevem algumas IOPs como: o coeficiente de absorção, o coeficiente de espalhamento e o coeficiente de atenuação de sinal. Os coeficientes de absorção e espalhamento possuem formulações semelhantes (Equações 1 a 4), sendo basicamente definidos como as variações totais da absorbância e da dispersão do meio por unidade de distância. E o coeficiente de atenuação se resume ao somatório desses coeficientes (Eq. 5).

$$A = \frac{\Phi a(\lambda)}{\Phi i(\lambda)} \quad B = \frac{\Phi b(\lambda)}{\Phi i(\lambda)} \quad \text{Equações (1) e (2)}$$

$$a(\lambda) = \frac{dA(\lambda)}{d\tau} \quad b(\lambda) = \frac{dB(\lambda)}{d\tau} \quad \text{Equações (3) e (4)}$$

$$c(\lambda)=a(\lambda)+b(\lambda) \quad \text{Equação (5)}$$

onde A e B se referem a absorvância e espalhamento totais do meio,  $\Phi_i$  é o fluxo radiante incidente (W),  $\Phi_a$  e  $\Phi_b$  são os fluxos radiantes absorvido e espalhado (W), respectivamente. T faz referência à espessura da camada de água em questão (m),  $a(\lambda)$  corresponde ao coeficiente de absorção ( $m^{-1}$ ),  $b(\lambda)$  é o coeficiente de espalhamento ( $m^{-1}$ ) e  $c(\lambda)$  refere-se ao coeficiente de atenuação do feixe.

Em contrapartida, as propriedades ópticas aparentes dependem tanto das propriedades do meio, como também da distribuição geométrica luminosa em determinado momento no espaço (Preisendorfer, 1976). Uma das AOPs mais conhecidas é reflectância de sensoriamento remoto ( $R_{rs}$ ) definida pela razão entre a radiância emergente dos oceanos e irradiância descendente:

$$R_{rs}(\theta, \phi, \lambda) = \frac{L_w(\theta, \phi, \lambda)}{E_d(\lambda)} \quad \text{Equação (6)}$$

onde  $R_{rs}$  confere a reflectância estimada por sensoriamento remoto ( $sr^{-1}$ ),  $L_w$  designa a radiância total emergente da superfície dos oceanos ( $W.m^{-2}.sr^{-1}$ ),  $E_d$  é a irradiância solar total ( $W.m^{-2}$ ),  $\lambda$  faz referência ao comprimento de onda, e  $(\theta, \phi)$  se referem às direções polar e azimutal, respectivamente.

## **1.2. Constituintes opticamente ativos presentes na água**


Os constituintes opticamente ativos presentes nos oceanos são as partículas ou moléculas que interagem com a luz de acordo com as propriedades ópticas descritas anteriormente. Geralmente são subdivididos em: água do mar

pura, fitoplâncton, CDOM e NAP, sendo que cada um destes componentes interage diferentemente com os fótons provenientes do sol. Em regiões oceânicas, as partículas fitoplanctônicas são dominantes, ao passo que em águas Tipo II isso não ocorre devido ao aumento das concentrações de materiais de origem continental (TSM e CDOM), fato que promove maior complexidade óptica ao ambiente. Nessas regiões as propriedades ópticas variam dinamicamente e não assumem relações lineares entre si, fazendo com que seja necessária a criação e otimização de algoritmos específicos para zonas costeiras. De maneira geral, o espectro de absorção (Figura 2) da água do mar tem o seu máximo na região do infravermelho próximo (NIR), diminuindo sua magnitude em comprimentos de onda mais curtos (azul e verde).

Os organismos fitoplanctônicos, por sua vez, possuem grande importância sobre a assinatura espectral de regiões tanto costeiras como oceânicas. Apesar da grande variedade de espécies, tamanhos e pigmentos, a interpretação das suas interações com a luz se torna uma tarefa complexa (Bricaud et al., 2004), porém o principal traçador da biomassa fitoplanctônica ainda é a concentração de clorofila-a (CHLa). Seu espectro de absorção (Figura 2) possui dois picos: um na faixa dos comprimentos de onda do azul (~440 nm) e outro no vermelho (~675nm), sendo que seu mínimo ocorre na faixa do verde (550 nm).

A CDOM, também conhecida como "*gelbstoff*" ou substâncias amarelas, corresponde ao grupo de substâncias orgânicas dissolvidas caracterizadas por ácidos húmicos e fúlvicos (IOCCG, 2000; Kirk, 1984). É geralmente encontrada

em maiores concentrações nas regiões costeiras. Sua curva de absorção é definida como uma função exponencial decrescente conforme aumentam os comprimentos de onda do visível (Figura 2). Seu pico de absorção ocorre nos comprimentos de onda mais curtos, sobretudo na faixa ultravioleta e azul.



**Figura 2.** Coeficiente de absorção da água do mar e seus principais constituintes.  $a_w$ = coeficiente de absorção da água pura,  $a_{CDOM}$ = coeficiente de absorção do CDOM,  $a_{ph}$ = coeficientes de absorção do fitoplâncton (CHLa),  $a_{NAP}$ = coeficientes de absorção das partículas não-algais e  $a_{tot}$ = somatório de todos os coeficientes de absorção. Figura modificada de Kratzer & Kowalczyk (2017).

Por fim, as partículas não-algais compreendem todo e qualquer material particulado em suspensão na coluna d'água não pertencente a grupos fitoplânctônicos, podendo ter constituintes orgânicos (i.e. detritos) ou inorgânicos (i.e. minerais e sedimentos), de forma que suas propriedades óticas inerentes podem variar de acordo com o tipo de material (Bowers & Binding, 2006). Contudo, seu padrão geral de absorção (Figura 2) apresenta um decréscimo à

medida que o comprimento de onda aumenta, possuindo um pico na faixa do azul. O espectro de reflectância (Figura 1), por sua vez e de maneira geral, possui maiores intensidades na faixa do verde e vermelho que aumentam proporcionalmente à concentração de NAP (Binding et al., 2005; Doxaran et al., 2002).

### **I.3. “Cor dos oceanos” estimada via sensoriamento remoto agua**

O sensoriamento remoto compreende a ciência que trata da aquisição de informações sobre a superfície terrestre através de sensores a bordo de aviões ou satélites, que detectam e registram a energia radiante refletida ou emitida pela mesma (Merchant, 2000). Estes sensores remotos podem ser classificados como ativos ou passivos. O sensoriamento remoto ativo trata de sensores que possuem sua própria fonte de energia eletromagnética. Já o sensoriamento remoto passivo se refere aos sistemas que detectam a energia eletromagnética naturalmente disponível (solar), que interage com os compartimentos da superfície da terrestre.

A “cor do oceano” é determinada por sistemas passivos de sensores radiométricos, que registram sinais eletromagnéticos na faixa do visível ao infravermelho próximo. Este campo da ciência possui inúmeras aplicações, como por exemplo: o mapeamento da produção primária global através da concentração clorofila, manejo de pesca, monitoramento do ciclo do carbono, da qualidade de água, saúde de recifes de corais e florestas de kelps, detecção de florações de

algas nocivas, estudos sobre as propriedades ópticas inerentes, maior entendimento sobre as mudanças climáticas, etc. (IOCCG, 2007).

Em 1978 foi lançado o primeiro sensor multiespectral passivo, o Coastal Zone Color Scanner (CZCS), o qual representou um grande avanço no que se refere à radiometria da superfície do mar (Gordon, 2010). A partir de então, novos sensores foram criados e aprimorados a fim de dar continuidade aos dados de cor do oceano, como foi o caso do *Sea-viewing Wide Field-of-view Sensor* (SeaWiFS), o qual já não se encontra mais em órbita. Atualmente, o *Moderate Resolution Imaging Spectroradiometer* (MODIS) a bordo dos satélites Terra e Aqua, que vem sendo amplamente utilizado nesta linha, contendo resolução temporal diária, e espacial de 250, 500 e 1000 metros, além de possuir 36 bandas, sendo 7 delas enquadradas no espectro do visível e 4 no NIR.

Porém, de acordo com Hu & Le (2014) esses sensores podem sair de operação em breve, uma vez que já estão em atividade há mais de 10 anos, e seus tempos de vida útil estavam previstos para 6 anos. Assim, o sensor *Visible Infrared Imaging Radiometer Suite* (VIIRS), lançado em 2012, surge como ferramenta alternativa para estudos radiométricos do oceano e corpos aquosos continentais (Cao et al., 2013; Cao et al., 2018; Hlaing et al., 2013; Jackson et al., 2013). Este sensor possui órbita polar com resolução temporal diária e espacial de 750 m e 350 m; contando com 22 bandas, sendo 5 delas dentro dos comprimentos de onda do visível e 2 no NIR.



### I.3.1. Correção atmosférica

A fim obter a radiância proveniente dos oceanos é necessário remover os efeitos da contribuição atmosférica da radiância total recebida pelos sensores acima do topo da atmosfera (IOCCG, 2010). A radiância total medida no topo da atmosfera é descrita como:

$$L_t(\lambda) = L_r(\lambda) + L_a(\lambda) + t(\lambda) \cdot L_w(\lambda) \quad \text{Equação (7)}$$

onde  $L_r(\lambda)$ ,  $L_a(\lambda)$  e  $L_w(\lambda)$  correspondem às radiâncias emitidas pelas moléculas gasosas (retroespalhamento de Rayleigh), pela atmosfera, e pelas águas oceânicas, respectivamente, enquanto  $t(\lambda)$  é a transmitância difusa na direção de visada.

Geralmente, os algoritmos de correção atmosférica utilizam as bandas do infravermelho próximo (NIR) para fazer essa remoção, visto que em regiões oceânicas quase todo sinal espectral nesta faixa é absorvido pelos oceanos. O modelo padrão NIR, proposto por Bailey et al. (2010) e utilizado pela NASA, segue esta lógica. Porém, a premissa do pixel com valor nulo de reflectância nestas bandas se torna inválida para águas do Caso II, onde as maiores contribuições de TSM provocam o aumento de reflectância no intervalo NIR (Siegel et al., 2000). Para estas regiões, outros algoritmos são propostos, dentre eles a correção descrita por Wang & Shi (2007), a qual utiliza também as bandas SWIR para desprezar os efeitos

atmosféricos, também conhecida como correção NIR-SWIR. Uma versão modificada deste método também foi proposta por Aurin et al. (2013). Além destes algoritmos, a correção proposta por Ruddick et al. (2000) também se torna aplicável em águas costeiras moderadamente turbidas. Este método assume homogeneidade espacial da razão das reflectâncias a 765 e 865 nm (NIR) tanto para a atmosfera como oceano, conhecida como a correção MUMM.

## Capítulo II: Objetivos

### II.1. Geral

Descrever o comportamento das propriedades e constituintes óticos da região estuarina e da pluma da Lagoa dos Patos, bem como avaliar suas inter-relações no âmbito de quantificar o material particulado em suspensão via sensoriamento remoto.

### II.2. Específicos

1. Identificar padrões de variabilidade espaço temporal das propriedades inerentes e aparentes e dos constituintes óticos da região do estuário da Lagoa dos Patos e sua pluma;
2. Caracterizar e quantificar a fluorescência *in situ* da clorofila-a da comunidade fitoplanctônica, a fluorescência da matéria orgânica dissolvida colorida e a concentração total de material em suspensão;

3. Comparar o desempenho de dois métodos de correção atmosférica para o mapeamento de TSM a partir dos sensores MODIS e VIIRS na região.
4. Elaborar algoritmos que correlacionem explicitamente a reflectância de sensoriamento remoto com as concentrações de material particulado em suspensão.

## Capítulo III: Área de Estudo

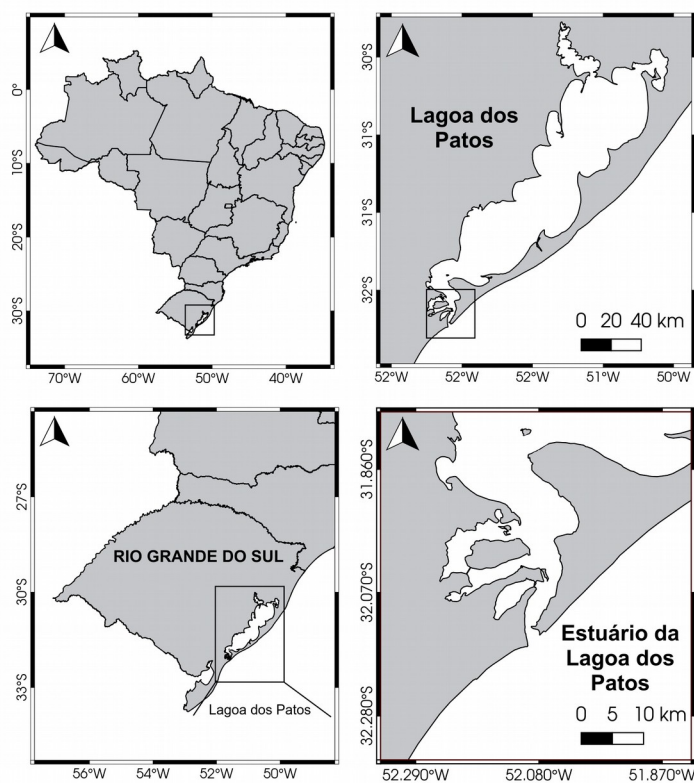
A Lagoa dos Patos é considerada a maior laguna estrangula do mundo, contendo uma área de 10.360 km<sup>2</sup>, 250 km de comprimento, 40 km de largura e profundidade média de 5 m. Localiza-se na planície costeira do estado do Rio Grande do Sul, entre as latitudes de 30°S e 32°S no Brasil e possui conexão com o Oceano Atlântico através de um canal com 20 km de comprimento e 3 km de largura na sua porção mais ao Sul (Kjerfve, 1986; Möller et al., 2001), como mostra a Figura 3. Cerca de 80% do seu corpo aquoso corresponde a águas continentais, enquanto que a porção salobra ocorre mais próxima ao canal de desembocadura. O complexo portuário localizado na porção Sul da Lagoa dos Patos no município de Rio Grande, apresenta grande importância social e econômica, sendo um dos maiores portos do Brasil (Medeiros et al., 2005). Intensas atividades antrópicas ocorrem na região (e.g. construção dos molhes,

dragagens, agricultura, etc.), as quais vem afetando diretamente a estrutura da pluma da laguna ao longo do último século.

Uma vez que o ambiente possui um regime de micro-marés, o vento e a descarga fluvial são as principais forçantes que determinam o padrão de circulação interna da laguna (Möller & Castaing, 1999; Möller et al., 2001, 1996), que por sua vez, regula os padrões deposicionais e de transporte sedimentar no local. A maior parte da drenagem continental na Lagoa provém de três tributários: o Rio Guaíba, que contribui com cerca de 61% da descarga total que chega no ambiente, seguido do Rio Camaquã e do Canal de São Gonçalo, respectivamente. Essas bacias de drenagem, em conjunto com processos de erosão costeira das margens da laguna, representam as principais fontes de sedimentos clásticos no corpo aquoso, que apresentam diferentes composições e distribuições granulométricas – de argila a areia grossa. O sedimento em suspensão presente na coluna d'água, contudo, é composto primariamente por silte e argila, com concentrações que variam de 5 até centenas de mg/L (Calliari et al., 2009; de Andrade Neto et al., 2012; Hartmann & Schettini, 1991; Tavora et al., 2019).

Durante períodos de baixa descarga fluvial, a circulação dentro da Lagoa é dominada pelo regime de ventos de NE-SO, que predominam na região. O efeito combinado das forçantes eólicas locais e remotas podem induzir fluxos bidirecionais, favorecendo o intercâmbio entre as águas continentais provindas do estuário da Lagoa dos Patos (ELP) e águas salinas a salobras oriundas das áreas oceânicas adjacentes. A predominância de ventos NE promove uma condição

resultante de vazante, ao passo que ventos dominantes de SO propiciam fluxos contrários em direção ao interior da laguna (Castelao & Moller Jr, 2006; Möller et al., 2001, 1996). Apesar destas eventuais condições de enchente, os fluxos vazantes são mais recorrentes, fazendo com que a Lagoa dos Patos seja uma importante fonte de TSM, composto principalmente por sedimentos finos, para a plataforma interna. Geralmente há a formação de uma pluma superficial hipopicnal o longo do seu curso, cuja deriva pode se dar transversalmente ou ao longo da costa (Antiqueira & Calliari, 2005; Calliari et al., 2009; Marques et al., 2010).



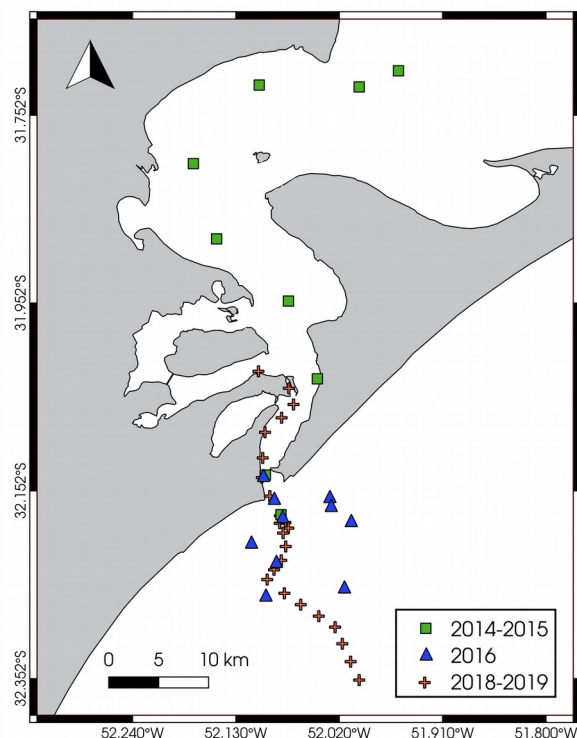
**Figura 3.** Localização da Lagoa dos Patos e da sua porção estuarina ao Sul.

# Capítulo IV: Materiais e Métodos

## IV.1. Delineamento amostral e medidas coletadas *in situ*

O conjunto de dados utilizado no presente trabalho foi obtido a partir de inúmeros cruzeiros que ocorreram nos anos de 2014, 2015, 2016, 2018 e 2019 (Figura 4), sendo que diferentes estratégias amostrais foram definidas ao longo deste período. Nos anos de 2014 e 2015 foram feitos transectos partindo do interior do PLE até a região costeira próxima ao canal de desembocadura, em 2016 as estações concentraram-se na região adjacente à pluma da laguna e nas campanhas de 2018 e 2019 as estações estavam distribuídas entre porção mais ao Sul do PLE até a plataforma interna (a aproximadamente 20 km da costa). As datas de cada campanha, bem como variação de concentração de TSM e o número de pontos coincidentes com a passagem dos sensores VIIRS e MODIS, utilizados para a construção dos algoritmos, são ilustrados na Tabela 1.





**Figura 4.** Localização das estações, diferenciadas pelos anos de amostragem. Os quadrados verdes representam os pontos coletados nos anos de 2014 e 2015, os triângulos azuis são referentes às estações coletadas em 2016, e os símbolos de adição laranjas são do período 2018-2019.

#### **IV.1.1. Medidas das propriedades óticas inerentes (IOPs) e dos constituintes opticamente ativos**


Os perfis verticais das IOPs foram obtidos com um sistema integrado de equipamentos da *SeaBird* e *Wet Labs*. Foram então utilizados: um ECO-2BB1FL para aquisição dos parâmetros de retroespalhamento e retroespalhamento particulado em 532 e 660 nm; um AC-9, o qual mede a absorção e atenuação da água em comprimentos de onda na faixa do visível (412, 440, 488, 510, 532, 555, 650, 676 e 715 nm), sendo este previamente calibrado para cada campanha

utilizando água purificada pelo sistema Milli-Q, segundo o protocolo disponibilizado para o equipamento; e um CTD Microcat SBE37SI para medidas de salinidade, pressão e temperatura. As concentrações de CDOM e CHLa foram estimadas através da fluorescência do sulfato de quinina dihidrato (QSDE) usando um ECO fluorímetro. Assim, os dados brutos de fluorescência foram convertidos para concentrações em ppb (CDOM) e mg.m<sup>-3</sup> (CHLa) utilizando os fatores de correção específicos de cada equipamento. Vale ressaltar que a concentração da chlorofila, por fluorometria in situ, não reflecte necessariamente a verdadeira concentração dos pigmentos.

**Tabela 1.** Data, número de observações usadas para calibrar e validar o algoritmo de TSM e variações da concentração de TSM em cada campanha.

<b>Date</b>	<b>Calibration</b>	<b>Validation</b>	<b>TSM (mg/L)</b>
16. set. 2014	3	0	12-88
17. set. 2014	3	1	37-85
5. nov. 2014	6	0	26-55
3. dez. 2014	0	0	32-83
4. dez. 2014	0	1	11-42
10. abr. 2015	0	5	5-14
30. nov. 2016	3	3	2-4
1. dez. 2016	1	0	15
2. dez. 2016	1	0	4
16. ago. 2018	0	1	3-14
17. ago. 2018	2	2	19-58
24. out. 2018	1	0	13-16
31. out. 2018	0	3	30-46
6. nov. 2018	3	0	7-56
3. abr. 2019	1	0	2-22
4. abr. 2019	4	0	0.5-4.5
31. jul. 2019	11	0	3-25
2. set. 2019	10	6	1-11
5. set. 2019	7	0	38-90
17. nov. 2019	0	7	36-52
29. nov. 2019	0	7	29-40
<b>Total</b>	<b>56</b>	<b>36</b>	<b>0.5-90</b>

Todos os sensores são acoplados em uma estrutura única metálica (Figura 5a) e conectados a um *datalogger* (DH-4). Para a leitura dos resultados gerados pelo DH-4 foi utilizado o *software WAP* (*Wet Labs Archive Processing*) que extrai e concatena os dados brutos. É importante ressaltar que, devido a questões logísticas, esses perfis verticais não puderam ser realizados em todas as estações.



**Figura 5.** Equipamentos utilizados para a aquisição das propriedades e constituintes ópticos. Equipamentos da Seabird e WetLabs utilizados para as medidas de IOPs, condutividade, temperatura e pressão, acoplados à estrutura metálica (a); o radiômetro HyperSAS posicionado na casaria da embarcação, utilizado para a aquisição das AOPs (b).

#### IV.1.2. Medidas radiométricas hiper-espectrais sobre a água

As AOPs foram coletadas em cada estação utilizando o radiômetro hiperespectral *HyperSAS* (Figura 5b), que mede a irradiância solar incidente, a

radiância total proveniente da superfície do mar e a radiância atmosférica em 137 comprimentos de onda na faixa do visível e infravermelho próximo (349 nm a 804 nm). O equipamento foi acoplado à casaria da embarcação e os dois sensores de radiância posicionados em uma direção de visada de 40° em relação ao nadir, seguindo os protocolos descritos pela agência espacial americana NASA (Mueller et al., 2000). As medidas duraram pelo menos 2 ou 3 minutos e ocorreram entre ângulos azimutais de 90° a 140°, quando possível. A partir dos dados brutos de tais sensores, foi possível calcular a reflectância por sensoriamento remoto utilizando a seguinte equação descrita por Mobley (1999):

$$Rrs(\lambda) = \frac{L_t(\lambda) - \rho_{sky} \cdot L_s(\lambda)}{E_d(\lambda)} \quad \text{Equação (8)}$$

Onde  $L_t(\lambda)$  refere-se à radiância total recebida pelo sensor,  $\rho_{sky}$  é o coeficiente reflectivo da interface ar-água,  $L_s(\lambda)$  corresponde à radiância proveniente da atmosfera e  $E_d(\lambda)$  representa a irradiância solar total. Visto que  $\rho_{sky}$  pode variar significativamente em resposta às alterações da velocidade do vento, cobertura de nuvens e campo de iluminação, foi criado um *look-up table* específico a partir do modelo numérico Hydrolight com base nas condições climáticas típicas da região. Após o cálculo de  $Rrs(\lambda)$ , os espectros resultantes foram submetidos a três testes de qualidade: (i) remoção de espectros contendo mais de 1% de valores não numéricos (NaN) ou negativos, (ii) remoção de dados adquiridos fora do intervalo dos ângulos de visada descritos anteriormente, (iii) eliminação de dados com desvio padrão maior do que 1 em relação à média dos espectros remanescentes. Também foram coletados dados ao longo da trajetória da embarcação para fins de validação atmosférica. Esses resultados também foram submetidos aos mesmos

filtros de qualidade e tiveram suas médias calculadas por pixel coincidente dos dados de satélite. Finalmente, os espectros resultantes foram convertidos para reflectância “saindo da água” (*water-leaving reflectance* –  $\rho$ ) adimensional através da multiplicação de cada valor de  $Rrs(\lambda)$  por  $\pi$ .

#### **IV.1.3. Medição do material particulado total em suspensão (TSM)**

As concentrações de TSM foram determinadas através do método gravimétrico clássico (Strickland & Parsons, 1972). Amostras superficiais de água foram coletadas usando uma garrafa de Niskin. Então, um volume conhecido destas alíquotas foi submetido ao processo de filtração a vácuo através de filtros de fibra de vidro (GF/F – 47 $\mu$ m) com pesos conhecidos. Posteriormente, esses filtros foram secos em estufa e novamente pesados em balança de precisão. A concentração de TSM foi então calculada com base na diferença entre os pesos inicial e final dos filtros sobre o volume total filtrado

#### **1 IV.1.4. Abordagem estatística utilizada para análise das observações *in situ***

Uma vez que as propriedades ópticas aparentes são fortemente influenciadas pelos constituintes opticamente ativos presentes no meio, uma análise de cluster (K-Means) foi aplicada aos espectros resultantes de  $\rho$  como tentativa de agrupar tais dados de acordo com a similaridade entre suas assinaturas espectrais. Todos os valores de reflectância foram normalizados utilizando  $\rho(583)$  para minimizar a influência da intensidade do sinal e favorecer a

forma de cada curva, já que nesta banda foram verificados picos de intensidade na maioria dos espectros.

Após a classificação espectral, foram feitas médias dos constituintes opticamente ativos no primeiro metro de profundidade, cujos resultados foram utilizados para uma análise de componentes principais (PCA). Assim, pudemos avaliar como cada constituinte opticamente ativo afetava a variabilidade das assinaturas espectrais. Além destas abordagens, também foi realizada uma análise de correlação de Pearson para melhor entender como as propriedades e constituintes ópticos correlacionavam-se entre si, bem como com as variáveis físicas do ambiente.

#### **IV.2. Aquisição e processamento dos dados de sensoriamento remoto**

Os dois sensores escolhidos para o desenvolvimento do algoritmo de TSM foram o *Moderate Resolution Imaging Spectroradiometer* (MODIS) e o *Visible Infrared Imaging Radiometer Suite* (VIIRS) a bordo dos satélites Aqua e NPP, respectivamente. O sensor MODIS possui 36 bandas distribuídas em três resoluções espaciais distintas – 28 bandas com 1 km de resolução, 4 bandas com 500 m e 2 bandas de 250 m. Convenientemente, uma das bandas de maior resolução está centrada em 645 nm, comprimento de onda escolhido por ser apropriado para o cálculo e mapeamento da concentração de TSM, sobretudo em regiões moderadamente túrbidas. Já o sensor VIIRS-NPP, possui 22 bandas com duas resoluções espaciais: 17 delas são bandas de moderada resolução (750 m),

5 são consideradas bandas de imageamento (375 m). Contudo, ferramentas de processamento (*software*) das bandas de alta resolução ainda não estão disponíveis. Por conta disso, aliado ao fato das bandas de moderada resolução possuírem ganho dual, que permite o sensor operar sem atingir a saturação sobre alvos de alta reflectância, as bandas escolhidas para a criação do algoritmo de TSM foram aquelas centradas em 671 e 745 nm (média resolução-750m).

Os dados dos dois sensores foram adquiridos através do Website *Ocean Color* da NASA (<https://oceancolor.gsfc.nasa.gov/>) com nível de processamento L1-A. Foram selecionadas as cenas coincidentes dos dias de coleta, as quais foram processadas utilizando o *plugin OceanColor Science Software* (OCSSW) do programa SeaDAS 7.5.3. via rotinas em bash em plataforma Linux. Os dados foram convertidos para o nível de processamento L2 para extrair as bandas de alta resolução e também para aplicar as correções atmosféricas adequadas às imagens.

#### **IV.2.1. Aplicação das correções atmosféricas**

A correção atmosférica padrão utilizada pela NASA tem como base a suposição de *black-pixel* em bandas do infravermelho próximo (NIR), a qual admite que ocorre absorção total dos comprimentos de onda desta faixa pela água pura. Porém, tal inferência pode induzir consideráveis erros na estimativa das reflectâncias em regiões costeiras, onde esta afirmativa nem sempre é válida (Siegel et al., 2000). Dado este fato, quatro esquemas de correções atmosféricas foram então testadas no presente trabalho: (1) a correção iterativa padrão NIR,

descrita anteriormente (sBailey et al., 2010); (2) o modelo de comutação padrão NIR-SWIR (Shi & Wang, 2007); (3) uma nova versão adaptada do método NIR-SWIR (Aurin et al., 2013); e (4) a correção MUMM (Ruddick et al. 2000).

A primeira correção (1) utiliza duas bandas no intervalo NIR para estimar a reflectância proveniente de aerossóis atmosféricos – 748 e 869 nm para sensor MODIS e 745-862 nm para o VIIRS. O algoritmo NIR-SWIR (2), por sua vez, combina o uso das bandas do NIR e do infravermelho de ondas curtas (SWIR) – entre 1200 e 2100 nm – para remover os sinais da contribuição atmosférica em águas não-túrbidas e túrbidas, respectivamente, de forma que se torna adaptável para ambas as condições na mesma cena. A versão adaptada deste método (3) foi proposta por Aurin et al. (2013), também com o intuito de estimar a radiância de corpos aquosos pouco a altamente túrbidos sem a contribuição de sinais atmosféricos. Este modelo tem o mesmo princípio do algoritmo NIR-SWIR padrão, mas as bandas SWIR são suavizadas por um filtro de média aplicado a cada janela de 3 por 3 pixels. Esta filtragem ocorreu antes do procedimento de correção atmosférica para tentar evitar o impacto dos baixos valores da razão sinal-ruído (SNR) naturais da banda SWIR do MODIS. Então, dois esquemas de criação de imagens L2 foram aplicados para cada cena, os quais foram posteriormente fundidos para a criação de uma única imagem. Um esquema utilizava a correção NIR iterativa padrão em regiões mais “claras” –  $R_{rs}(645) < 0.01 \text{ sr}^{-1}$  – e outro, uma correção SWIR forçada em regiões mais túrbidas –  $R_{rs}(645) \geq 0.01 \text{ sr}^{-1}$ .



Por fim, o algoritmo MUMM também foi aplicado, o qual é baseado na suposição de homogeneidade espacial da razão de duas bandas NIR (as mesmas utilizadas na correção iterativa padrão) tanto para a atmosfera, quanto para o oceano, de forma que se torna possível separar os dois sinais.

#### **IV.2.2. Procedimentos de *match-up***

O exercício de *match-up* se refere à comparação entre as reflectâncias coletadas *in situ* e por sensoriamento remoto, como ferramenta para avaliar a eficácia das correções atmosféricas utilizadas no trabalho (Secção IV.3.2.1.). Esse procedimento foi conduzido seguindo a mesma lógica descrita nos trabalhos de Goyens et al. (2013) e Jamet et al. (2011), os quais baseiam-se no protocolo da NASA (Bailey & Wang, 2001). Contudo, alguns critérios de exclusão foram aplicados previamente às comparações propriamente ditas. Primeiramente, os dados de  $\rho$  coletados *in situ* em um intervalo de tempo maior que 2 horas da passagem dos sensores foram excluídos. Por conseguinte, foram calculados os valores médios e de desvio padrão em janelas de 3 por 3 pixels centradas nos pontos de coleta. Os pontos onde mais de 3 pixels contidos nas janelas foram mascarados, bem como onde o desvio padrão correspondia a mais 20% do valor da média também foram excluídos da análise.

Além deste processo, as medidas hiperespectrais coletadas em campo foram integradas pela resposta espectral relativa de cada sensor para obter as bandas ponderadas equivalentes às bandas centradas em 645 nm (B1) do MODIS e em 671 e 745 nm (M5 e M6) do VIIRS, como é descrito nos estudos de Nechad

et al. (2010b) e Zhang et al. (2010). Por fim, as métricas estatísticas utilizadas para avaliar a acurácia e incertezas dos *match-ups* de cada banda centrada foram: (i) o coeficiente de correlação de Spearman ( $r$ ), (ii) a raiz do erro quadrático médio (RMSE), (iii) o erro médio absoluto relativo (MAPE) e (iv) o erro médio relativo ou viés. Essas métricas foram calculadas da seguinte forma:

$$\text{RMSE}_{\text{match-up}} = \sqrt{\frac{\sum_{i=0}^{n-1} (\rho_{\text{sat}} - \rho_{\text{in situ}})^2}{N}} \quad \text{Equação (9)}$$

$$\text{MAPE}_{\text{match-up}} = \frac{1}{N} \sum_{i=0}^{n-1} \left| \frac{\rho_{\text{sat}} - \rho_{\text{in situ}}}{\rho_{\text{in situ}}} \right| \times 100\% \quad \text{Equação (10)}$$

$$\text{Bias}_{\text{match-up}} = \frac{1}{N} \sum_{i=0}^{n-1} \frac{\rho_{\text{sat}} - \rho_{\text{in situ}}}{\rho_{\text{in situ}}} \times 100\% \quad \text{Equação (11)}$$

Onde  $N$  corresponde ao número de observações,  $\rho_{\text{in situ}}$  e  $\rho_{\text{sat}}$  são as reflectâncias medidas em campo e pelos sensores remotos, respectivamente. A fórmula do coeficiente de correlação de Spearman ( $r$ ) não é demonstrada aqui por brevidade.

### IV.3. Desenvolvimento e avaliação dos modelos de TSM

Regressões lineares foram efetuadas entre os valores de  $\rho$  e TSM coletados *in situ* sob uma variedade de concentrações para encontrar as melhores ajustagens com erros mínimos. No final deste processo, obtivemos um modelo de TSM criado a partir de  $\rho(645)$  do MODIS-Aqua e dois outros a partir de  $\rho(671)$  e  $\rho(745)$  do VIIRS-NPP. Algoritmos polinomiais foram construídos a partir das

bandas do vermelho (de segunda ordem), enquanto que a banda NIR deu origem a um modelo de primeira ordem.

Uma vez que foi averiguada a saturação das bandas do vermelho quando as concentrações de TSM eram mais altas, decidiu-se por aplicar um algoritmo de transição do tipo proposto por Novoa et al. (2017), que seleciona a faixa mais sensível de  $\rho$  em relação ao aumento de TSM sem que haja saturação. Como resultado final, obtivemos um modelo transicional unindo os algoritmos criados a partir de  $\rho(671)$  e  $\rho(745)$  para estimar a concentração de TSM na água. Para tanto, foi definido um ponto de troca entre esses modelos baseado na relação entre as reflectâncias na faixa do vermelho e do NIR. Uma curva de regressão logarítmica foi construída a partir da comparação entre  $\rho(671)$  e  $\rho(745)$  coletadas *in situ* e convolucionadas para os centros de banda do VIIRS. Esse processo só pôde ser realizado para este sensor, uma vez que o HyperSAS não possui a faixa necessária para fazer a convolução da banda centrada em 859 nm do sensor MODIS. Então, uma vez que a curva foi definida, o ponto de saturação de  $\rho(671)$  foi determinado pelos valores de  $x$  e  $y$  onde a inclinação da reta tangente a este ponto era igual a 1. O mesmo procedimento foi realizado para as curvas inferior e superior com 95% de nível de confiança. Para valores de  $\rho(671)$  inferiores ao ponto de saturação da curva inferior do intervalo de confiança, o modelo polinomial da banda do vermelho foi aplicado, enquanto que para valores acima do ponto de saturação da curva superior do intervalo de confiança, o modelo linear da banda NIR foi empregado. Finalmente, para valores de  $\rho(671)$  dentro dos

limites dos pontos de saturação de ambas as curvas de confiança, um modelo ponderado entre os algoritmos das bandas do vermelho e NIR foi utilizado para garantir uma transição suavizada entre os valores estimados de TSM, como demonstra a seguinte fórmula:

$$TSM_{\text{vermelho-NIR}} = \alpha * TSM_{\text{vermelho}} + \beta * TSM_{\text{NIR}} \quad \text{Equação (12)}$$

$$\alpha = \frac{\ln\left(\frac{S_{95+}}{\rho^{(671)}}\right)}{\ln\left(\frac{S_{95+}}{S_{95-}}\right)} \quad \beta = \frac{\ln\left(\frac{\rho^{(671)}}{S_{95+}}\right)}{\ln\left(\frac{S_{95+}}{S_{95-}}\right)} \quad \text{Equações (13) e (14)}$$

Onde S refere-se ao ponto de saturação da curva, S95+ e S95- correspondem aos pontos de saturação das curvas superior e inferior, respectivamente. TSM<sub>vermelho-NIR</sub>, TSM<sub>vermelho</sub> e TSM<sub>NIR</sub> são as concentrações de TSM calculadas pelos modelos ponderado, polinomial da banda do vermelho e linear da banda do NIR. Informações mais detalhadas sobre o desenvolvimento deste método, bem como todas as formulações do mesmo são descritos por Novoa et al. (2017).

As métricas estatísticas utilizadas para avaliar a acurácia e incertezas associadas a cada modelo foram: (i) o coeficiente de determinação (R<sup>2</sup>), (ii) a raiz do erro quadrático médio (RMSE), (iii) o erro médio absoluto percentual, ou relativo (MAPE) e (iv) o erro médio relativo ou viés. Esses parâmetros foram calculados como da seguinte forma:

$$RMSE_{TSM} = \sqrt{\frac{\sum_{i=0}^{n-1} (\hat{y} - y_i)^2}{N}} \quad \text{Equação (13)}$$

$$MAPE_{TSM} = \frac{1}{N} \sum_{i=0}^{n-1} \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad \text{Equação (14)}$$

$$Bias_{TSM} = \frac{1}{N} \sum_{i=0}^{n-1} \frac{\hat{y}_i - y_i}{y_i} \times 100\% \quad \text{Equação (15)}$$

Onde N corresponde ao número de observações,  $y_i$  e  $\hat{y}_i$  são os valores medidos e estimados de TSM do  $i$ -ésimo elemento, respectivamente. A fórmula do  $R^2$  não é demonstrada aqui por brevidade.

O presente conjunto de dados de calibração não pôde ser dividido em subconjuntos de treinamento e teste devido ao seu tamanho amostral, como seria ideal. Pensando nisso, todas as métricas apresentadas a cima foram computadas utilizando a técnica de validação cruzada com o método K-fold. Esta ferramenta estatística nos permite dividir aleatoriamente o conjunto total de dados em k subconjuntos menores, então a curva de regressão é ajustada utilizando k-1 *folds* ou subconjuntos como dados de treinamento do algoritmo, enquanto que o subconjunto restante é utilizado como dado teste (ou dados ainda não vistos) para validar o algoritmo resultante. O número de K subconjuntos foi determinado com base no tamanho do conjunto de dado disponível e de acordo com a configuração que garantiu a computação das melhores métricas para ambos os subconjuntos de teste e treinamento. Então, os valores apresentados nas seguintes seções consistem nas médias de cada métrica estatística computada para cada subconjunto de teste.

Para fins de comparação, também foi testado e pré-calibrado o algoritmo semi-analítico desenvolvido por Nechad et al. (2010), o qual vem sendo amplamente utilizado em outros estudos para estimar as concentrações de TSM em águas altamente/moderadamente túrbidas (Novoa et al., 2017; Tavora et al., 2019; Vanhellemont & Ruddick, 2015).

#### **IV.4. Validação dos algoritmos resultantes de TSM**

Após o processo de calibração e criação dos modelos de TSM descrito na seção precedente, um conjunto suplementar de medidas *in situ* de TSM (36 amostras) foi comparado com os valores de TSM simultâneos estimados pelos dois sensores, como forma de validação desses algoritmos. Esses dados adicionais foram coletados durante as mesmas campanhas descritas na Seção IV.1. A mesma metodologia apresentada na Seção IV.2.2. foi aplicada a cada ponto de coleta (e.g. média e desvio padrão em 3 por 3 pixels, CV menos que 20%), com exceção à tolerância do tempo em relação à passagem dos sensores. Neste caso, um intervalo de até 3 horas foi considerado, apesar dos pontos pertencentes a esta faixa corresponderem a 7% de todo o conjunto de dados. O restante dos pontos estava dentro do intervalo recomendado de 2 horas. As mesmas métricas estatísticas explicadas na seção precedente foram utilizadas para avaliar as performances de cada algoritmos sob diferentes correções atmosféricas.

## Capítulo V: Artigo Científico

Para a obtenção do título de Mestre pelo Programa de Pós-Graduação em Oceanografia Física, Química e Geológica, é requerido que o discente realize a submissão de pelo menos um artigo científico como primeiro autor em periódico com corpo indexado. Desse modo, os resultados da pesquisa desenvolvida durante o período de mestrado e a discussão dos resultados serão apresentados em forma de artigo neste Capítulo. O primeiro manuscrito, de autoria de **Luiza Luz Sartorato e Carlos Alberto Eiras Garcia**, é intitulado “**Assessing the potential for retrieving total suspended matter in Patos Lagoon (Brazil) through MODIS/Aqua and VIIRS/NPP data**” e será submetido para publicação no periódico “**Remote Sensing of Environment**”.

# Assessing the potential for retrieving total suspended matter in Patos Lagoon (Brazil) through MODIS/Aqua and VIIRS/NPP data

Luiza Sartorato\* and Carlos Alberto Eiras Garcia

Instituto de Oceanografia, Universidade Federal do Rio Grande – FURG, Rio Grande Brazil

---

## Abstract

The concern regarding the health of marine environments is a global issue, and total suspended matter (TSM) concentration is one great proxy for coastal water quality. Then, the passive remote sensing arises as a tool for estimating TSM and monitoring large estuaries synoptically, where appropriate atmospheric corrections are often required. The present work aims to identify patterns of variability of optical properties in a Brazilian coastal lagoon, assess four atmospheric correction schemes and develop an accurate empirical model to estimate the TSM concentration from MODIS-Aqua (250-m) and VIIRS-SNPP (750-m) sensors. Field campaigns have been performed from 2014 to 2019 when optical properties and seawater constituents were measured. The standard iterative NIR, two NIR-SWIR switching algorithms, and the MUMM correction were applied to the images, and two bands in red and near-infrared (NIR) intervals were chosen for estimating TSM concentration. The results showed that the Patos Lagoon waters present a co-dominance between CDOM and TSM on its optical characteristics, which strongly influences the water-leaving reflectance variability. The NIR and NIR-SWIR based atmospheric correction algorithms presented better results. Finally, a transitional algorithm between red and NIR bands was developed to better estimate TSM when strong gradients are formed from inner to the outer lagoon.

*Keywords:* Total suspended matter, optical remote sensing, atmospheric correction, algorithms, optical complexity, active optical constituents.

---

\*Corresponding authors

\*\*Current address: Campus Carreiros – Av. Itália Km 8, Carreiros, RS, 96203-900

Email addresses: [luizalsartorato@gmail.com](mailto:luizalsartorato@gmail.com) (Luiza L. Sartorato), [garcia.io.furg@gmail.com](mailto:garcia.io.furg@gmail.com) (Carlos A. E. Garcia)



## 1 **1. Introduction**

1 Nearly half of the global population lives within 100 kilometers of the coasts (Small  
2 & Nicholls, 2003), and considering that rivers and lagoons represent important sources of  
3 dissolved and particulate matter to the ocean, it is essential to monitor estuaries and the  
4 anthropic impact on these regions. In 2008, the European Union established the Marine  
5 Strategy Directive Framework, which requires all Member States to take the necessary  
6 measures to protect and preserve its marine environments (Howarth, 2008)(Howarth,  
7 2008). Likewise, in Brazil, the National Environment Council instituted legal resolutions  
8 that define coastal bathing water criteria and classification, as well as settled standards for  
9 effluent released into natural water bodies (CONAMA, 2012). Regarding this scenario,  
10 total suspended matter (TSM) might be used as a proxy of coastal water quality since it  
11 directly affects light penetration, which limits biological productivity, and also might carry  
12 out some pollutants (Bilotta & Brazier, 2008; Newcombe & MacDonald, 1991; Niencheski  
13 & Baumgarten, 2000; Williamson et al., 1996).

14 Despite the importance of such variable in coastal environments, the field-based  
15 methodology for measuring TSM, along with its expensive costs, still limit data coverage in  
16 time and space. This fact reinforces the need for monitoring large estuaries and coastal  
17 areas synoptically so that some studies suggest the use of optical remotely sensed data to  
18 indirectly estimate TSM (J. Acker et al., 2005; Binding et al., 2005; Doxaran et al., 2016;  
19 Knaeps et al., 2015; Nechad et al., 2010a; Zhang et al., 2010). Since estuaries are extremely  
20 dynamic environments, the concentration of suspended particles might vary significantly,  
21 and consequently, it might present patchiness in various scales - from centimeters to  
22 kilometers. According to Aurin et al. (2013), the optimal spatial resolution for resolving this  
23 heterogeneity in near shore regions is at least 630 m. Currently, the sensors Landsat-OLI,  
24 Sentinel3-OLCI and Sentinel2-MSI present good spatial resolutions (10 m, 300 m, and 20  
25 m respectively), but relatively low temporal resolutions (revisit time of 16-days, daily, 5-  
26 days), which avoid a more accurate description of the environmental dynamics. Hence, the  
27 Moderate Resolution Imaging Spectroradiometer onboard the Aqua satellite  
28 (MODIS/Aqua), and the Visible Infrared Imaging Radiometer Suite onto the Suomi

29 National Polar-orbiting Partnership spacecraft (VIIRS/SNPP) have been extensively used  
30 for this purpose over the years because of its great offset between spatial and temporal  
31 resolutions (both daily and 250-m and 750-m, respectively), which in most of the cases,  
32 fairly represents the high variability of the TSM concentrations in coastal regions.

33 The development of algorithms from remote sensing data requires apparent and  
34 inherent optical properties (AOP and IOP, respectively) *in situ* measurements for calibration  
35 and validation purposes (Doxaran et al., 2004). However, these properties usually  
36 demonstrate considerable variations in coastal waters, where the active optical constituents  
37 (e.g. TSM, chromophoric dissolved organic matter, phytoplankton) do not co-vary linearly  
38 (IOCCG, 2000). Hence, understanding the optical complexity is essential for developing  
39 robust algorithms for TSM retrieval, since co-dominance effects between two or more  
40 active constituents of the medium may be present, as well as using the appropriate  
41 atmospheric correction, once the black-pixel assumption vanishes over nearshore waters  
42 (Wang & Shi, 2007).

43 A global model for TSM does not exist so far, nevertheless, several algorithms have  
44 been developed over the decades to establish relationships between oceanic optical  
45 properties and TSM (Allison et al., 2010; Han et al., 2016; Siswanto et al., 2011), which  
46 are usually classified as (1) empirical and (2) semi-analytical models. The empirical  
47 algorithms establish a direct relationship between the apparent optical properties (e.g.  
48 reflectances, water-leaving radiance) and the concentration of the constituent of interest  
49 using coincident *in situ* measurements. Despite their simplicity, easy implementation and  
50 low computing time, these models are regionally limited and more sensitive to variations in  
51 the amount of optical constituents and type of particles in water (IOCCG, 2000). The semi-  
52 analytical approaches, on the other hand, implement both the relationship between the *in*  
53 *situ* retrieved inherent properties and the water-leaving spectra, using radiative-transfer  
54 models to solve light propagation in water. The resulting algorithms can estimate the  
55 concentration of the desired constituent based on the reflectance or radiance spectra  
56 (Ioannou et al., 2011; IOCCG, 2000). Although these inverse models have demonstrated

57 good results in coastal regions, they are usually more complex to implement and require  
58 higher computational performance.

59 Although many remote sensing algorithms have been validated in Brazilian waters  
60 (Fassoni-Andrade & Paiva, 2019; Novo et al., 2006; Rudorff et al., 2018; Villar et al., 2012;  
61 Vital, 2015), just a few studies were conducted for this purpose in the Patos Lagoon estuary  
62 (Costi et al., 2017; Pagot et al., 2007; Tavora et al., 2019). None of those studies in the  
63 Patos Lagoon estuary included measurements of optical properties. In order to overcome  
64 this lack of knowledge, the present study aims to (i) optically characterize and identify  
65 patterns of variability of apparent and inherent properties, as well as optically active  
66 constituents in the Patos Lagoon estuarine system; (ii) assessing four atmospheric  
67 correction methods, in the region (iii) develop accurate empirical models to estimate the  
68 TSM concentration in the region. The best algorithm to estimate TSM will be implemented  
69 in the Brazilian Coastal Monitoring System (SiMCosta) to provided TSM concentration  
70 maps on a daily basis for the coastal community end-users.

## 71 **2. Study Area**

72 The Patos Lagoon is considered the world's largest choked lagoon, comprising a  
73 total surface area of 10.360 km<sup>2</sup> with dimensions of 250 km and 40 km in length and width  
74 and an average depth of 5 m. It is located in a coastal plain of Rio Grande do Sul state,  
75 between the latitudes of 30°S and 32°S in southern Brazil (Figure 1), and is connected to  
76 the South Atlantic ocean via a 20 km entrance narrow channel of 3 km in width, in its  
77 southernmost portion (Kjerfve, 1986; Möller et al., 2001). About 80% of its body  
78 corresponds to freshwaters, while the saltier portion occurs southwards.

79 Since the study area presents a micro-tidal regime, the wind and river discharge  
80 represent the two main forcings controlling its internal circulation (Möller & Castaing,  
81 1999; Möller et al., 2001, 1996), which in turn regulate deposition and transport patterns of  
82 TSM. The lagoon receives freshwater from three major tributaries: the Guaíba River, which  
83 contributes with 61% of total discharge into the lagoon, followed by the Camaquã river and

84 the São Gonçalo channel, respectively. These drainage basins, along with the coastal  
 85 erosion on lagoon's margins, represent the main sources of clastic sediments in the Patos  
 86 Lagoon, which might present different granulometric distributions – from clay to coarse  
 87 sand. The suspended sediment in the water column, however, is composed primarily by silt  
 88 and clay, with concentrations ranging from 5 up to hundreds mg/L (Calliari et al., 2009; de  
 89 Andrade Neto et al., 2012; Hartmann & Schettini, 1991; Tavora et al., 2019).

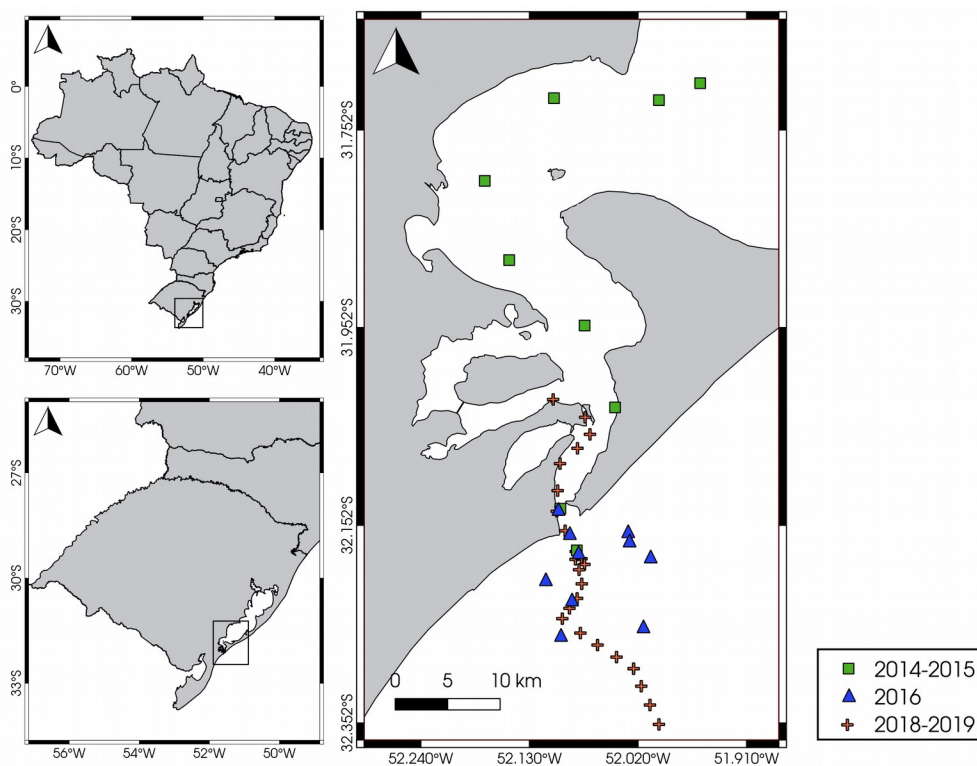
**Table 1.** Date, number of observations used to calibrate and validate the TSM algorithm, and TSM concentration ranges of each campaign.

<b>Date</b>	<b>Calibration</b>	<b>Validation</b>	<b>TSM (mg/L)</b>
16. set. 2014	3	0	12-88
17. set. 2014	3	1	37-85
5. nov. 2014	6	0	26-55
3. dez. 2014	0	0	32-83
4. dez. 2014	0	1	11-42
10. abr. 2015	0	5	5-14
30. nov. 2016	3	3	2-4
1. dez. 2016	1	0	15
2. dez. 2016	1	0	4
16. ago. 2018	0	1	3-14
17. ago. 2018	2	2	19-58
24. out. 2018	1	0	13-16
31. out. 2018	0	3	30-46
6. nov. 2018	3	0	7-56
3. abr. 2019	1	0	2-22
4. abr. 2019	4	0	0.5-4.5
31. jul. 2019	11	0	3-25
2. set. 2019	10	6	1-11
5. set. 2019	7	0	38-90
17. nov. 2019	0	7	36-52
29. nov. 2019	0	7	29-40
<b>Total</b>	<b>56</b>	<b>36</b>	<b>0.5-90</b>

90 During the absence of large freshwater discharges, the circulation within the lagoon  
 91 is dominated by a NE-SW wind regime. The combined effects of local and non-local  
 92 forcings might induce the water exchange between the estuary of Patos Lagoon (EPL) and

93 the adjacent coastal ocean. When north-easterly winds prevail, this trade tends to seaward,  
94 usually resulting in an ebb condition. Conversely, south-westerly winds boost landward  
95 flows and the entrance of saline waters into the ELP (Castelao & Moller Jr, 2006; Möller et  
96 al., 2001, 1996). Nevertheless, in most cases, the estuary is predominantly dominated by  
97 ebb flows and the Patos Lagoon comprises an important source of TSM (especially of fine  
98 materials) to the inner shelf, and along this flow a small to average-size hypopycnal plume  
99 is formed on the first meters of water column, displaying both alongshore and offshore  
100 drifts (Antiqueira & Calliari, 2005; Calliari et al., 2009; Marques et al., 2010).

101 The Rio Grande Port situated in the PLE, southern Brazil, has great social and  
102 economic importance, being one of the largest marine ports in Brazil (Medeiros et al.,  
103 2005), where intense anthropic and dredging activities occur.



**Figure 1.** Study area and location of sampled stations. The squares represent the stations collected in 2014-2015, the triangles represent the stations collected in 2016 and the plus signs the stations collected in 2018-2019.

## 104 **3. Methods**

### 105 **3.1. Field Campaigns and *in situ* measurements**

106 The *in situ* dataset was acquired from several cruises, with different sampling  
107 designs in the EPL, in its plume, and adjacent oceanic regions during 2014, 2015, 2016,  
108 2018 and 2019 (Figure 1). In 2014-2015 the data were collected mainly in the EPL region  
109 (9 stations) with a few stations outside the lagoon, while in 2016 almost all stations  
110 occurred on the plume with only 2 stations within the channel's mouth. The 2018 and 2019  
111 campaigns, on the other hand, occurred from the EPL up to the inner shelf (approximately  
112 20 km from the coast). This dataset consisted of several IOP, AOP, and TSM concentration  
113 measurements. All these data were used to understand the optical complexity of the  
114 environment, to validate the atmospheric corrections tested (match-ups), and to develop the  
115 TSM algorithm.

116 The AOPs were collected continuously during the navigation, as well as at each  
117 station. The along-track data were used in the match-up exercise (atmospheric validation),  
118 while the other dataset was compared with the TSM concentrations collected at the  
119 correspondent station. The TSM model development consisted in two steps: (i) the  
120 calibration process, which the algorithm was effectively created from *in situ* AOP data, and  
121 (ii) the validation process when additional *in situ* TSM measurements were compared to the  
122 TSM concentrations estimated from the sensors at the same point. Table 1 shows the dates  
123 of each campaign, as well as the range of the TSM concentrations and the number  
124 observations used in for calibrating and validating the TSM algorithm.

#### 125 **3.1.1. Measurements of inherent optical properties and active optical constituents**

126 All the IOPs measurements were performed in vertical profiles using SeaBird and  
127 WET Labs instruments. We used an ECO-2BB1FL for acquiring particulate backscattering  
128 ( $b_{bp}$ ) at 532 and 660 nm; an AC-9 for measuring absorption ( $a$ ) and beam attenuation  
129 coefficients ( $c$ ) at 9 wavelength (412, 440, 488, 510, 532, 555, 650, 676 e 715 nm), which  
130 was previously calibrated with Mili-Q water for correcting the instrumental drifts; and

131 finally, we used a CTD Microcat SBE337SI for measuring salinity and temperature in water  
132 column. The colored dissolved organic matter (CDOM) and chlorophyll-a (CHLa)  
133 concentrations were estimated through the fluorescence of Quinine Sulfate Dihydrate  
134 Equivalent (QSDE) using ECO Fluorimeters. The raw fluorescence data were converted to  
135 CDOM concentration in ppb, and CHLa in mg.m<sup>-3</sup> using the instrument-specific correction  
136 factors provided by SeaBird and WET Labs.

137 These instruments were attached altogether in a metal frame and connected in a  
138 DH-4 data logger. Lately, these products were extracted and unified using the WET Labs  
139 Archive Processing software. Due to the sea conditions, these vertical profiles did not occur  
140 in every station.

141 The TSM concentrations were determined by the classical gravimetric method  
142 (Strickland & Parsons, 1972). The water samples collected within the first meter of depth  
143 using a Niskin bottle, and then known volumes were filtered at low vacuum through pre-  
144 weighed glass fiber filters (GF/F – 47 micrometers). After dried, the filters were weighed in  
145 a precision balance and the TSM concentration was calculated based on weights and the  
146 total filtered volume. Unfortunately, no replicates have been made due to cruise logistics.

### 147 **3.1.2. Above-water hyperspectral radiometric measurements**

148 The AOP properties were collected in each station with a HyperSAS hyperspectral  
149 radiometer (Satlantic), which measures solar (downwelling) irradiance, and total upwelling  
150 and sky radiances simultaneously in 137 wavelengths (349 to 804 nm). The equipment was  
151 attached to the deckhouse of the vessel, and the two radiance sensors were placed at a  
152 viewing direction of 40° from nadir, following NASA protocols (Mueller et al., 2000). Each  
153 measurement lasted at least 3 minutes and occurred over a range of relative azimuth angles  
154 from 90 to 140°. The remote sensing reflectance ( $R_{rs}$ ) was then calculated from these  
155 radiometric products according to the equation described by Mobley (1999):

$$Rrs(\lambda) = \frac{L_t(\lambda) - \rho_{sky} \cdot L_s(\lambda)}{E_d(\lambda)} \quad (1)$$

156 where  $L_t(\lambda)$  refers to the total upwelling radiance,  $\rho_{\text{sky}}$  is the reflective coefficient of the  
157 air-ocean interface,  $L_s(\lambda)$  is the sky radiance, and the  $E_d(\lambda)$  is the solar downwelling  
158 irradiance. Since  $\rho_{\text{sky}}$  strongly varies with wind speed, cloud cover, and solar illumination, a  
159 specific look-up table, based on the typical weather and solar conditions in EPL, was  
160 created using the Hydrolight numerical model. After the  $R_{rs}(\lambda)$  calculation, the resulting  
161 spectra were subjected to three quality filters: (i) removal of spectra containing more than  
162 1% of either missing (NaN) or negative values, (ii) removal of data acquired outside the  
163 range of viewing angles described above, and (iii) elimination of data with standard  
164 deviation greater than 1 to the average of remaining spectra. Finally, the resulting spectra  
165 were converted to dimensionless water-leaving reflectance ( $\rho_w$ ) by multiplying each  $R_{rs}(\lambda)$   
166 value by  $\pi$ . For atmospheric validation purposes, radiometric measurements were also  
167 collected continuously along the navigation path. The spectra passing the same quality  
168 filters were averaged per coincident pixel of satellite data.

### 169 **3.2. Statistical analysis for the *in situ* observations**

170 Since the apparent properties are strongly influenced by the optically active  
171 constituents in the water, a cluster analysis was performed over the resulting *in situ* water  
172 reflectance spectra to group the dataset according to its shape similarities. To minimize the  
173 influence of signal intensity and favor the shape of each spectrum, all *in situ*  $\rho_w(\lambda)$  were  
174 normalized by  $\rho(583)$  before this analysis, since a peak was verified at this wavelength for  
175 most of the spectra. Once the spectral classes were defined, its optical composition was  
176 averaged in the first meters of depth, then a Principal Component Analysis (PCA) were  
177 generated to understand how each optically active constituent affects the spectral signatures  
178 variability. A Pearson correlation analysis was also implemented in the data from the IOP  
179 profiles as an attempt to better understand how the optical and physical variables interrelate  
180 in the environment. All the data were averaged over the entire water column for this latter  
181 analysis.



### 182 3.3. Remotely sensed data acquisition and processing

183 The two chosen sensors to build the TSM algorithm were MODIS (Moderate  
184 Resolution Imaging Spectroradiometer) and VIIRS (Visible Infrared Imaging Radiometer  
185 Suite), onboard the Aqua and NPP satellites, respectively. The first has 36 bands distributed  
186 in three spatial resolutions – 28 bands with 1-km, 4 bands with 500-m and 2 bands with  
187 250-m. The latter high-resolution bands are centered at 645, which is an appropriate  
188 wavelength for mapping TSM, and was consequently selected to achieve this goal. VIIRS-  
189 NPP has 22 bands in two spatial resolutions: 16 moderate-resolution bands (750-m), 5  
190 imagery-resolution bands (375-m), and one Day-Night band (750-m). Due to the dual-gain  
191 of the moderate bands, the sensor can operate without saturating over high reflectance  
192 targets (e.g. land or clouds) and, for this reason, the bands M4, M5 and M6 centered at 672  
193 and 745 (750-m) were selected for TSM determination.

194 MODIS-Aqua and NPP-VIIRS Level 1-A remotely sensed data were downloaded  
195 from NASA's Ocean Color Website (<https://oceancolor.gsfc.nasa.gov/>) on the same date of  
196 the field campaigns, and then routinely processed using the open-source software SeaDAS  
197 7.5.3 in conjunction with the OceanColor Science Software (OCSSW) plugin in a Linux  
198 platform. The data were converted from Level 1-A to Level 2 to maintain the higher  
199 resolutions and also to apply different atmospheric corrections to the images.

#### 200 3.3.1. Atmospheric Corrections

201 The standard atmospheric correction based on the black-pixel assumption in  
202 infrared (NIR) bands usually introduces large uncertainty in coastal regions (Siegel et al.,  
203 2000). Given this fact, four atmospheric correction algorithms were tested: (1) the standard  
204 NIR correction (Bailey et al., 2010); (2) the NIR-SWIR (shortwave infrared) switching  
205 model (Wang & Shi, 2007); (3) the modified NIR-SWIR algorithm (Aurin et al., 2013); and  
206 (4) the MUMM correction (Ruddick et al., 2000a). For all L2gen (SeaDAS routine)  
207 schemes, the SWIR bands (2130 nm for MODIS and 2250 nm for VIIRS) were used to  
208 mask clouds with a threshold albedo of 0.018 to avoid masking turbid waters. After this

209 procedure, all unrealistic values of  $R_{rs}$  were discarded, such as negative values or those  
210 above  $0.15 \text{ sr}^{-1}$ , and then converted to water-leaving reflectance ( $\rho$ ).

211 The first one (NIR) uses two bands in the NIR interval for estimating the aerosol  
212 reflectance – 748-869 nm for MODIS, and 745-862 nm for VIIRS – and an iterative  
213 procedure to estimate NIR reflectance in moderate turbid waters. The NIR-SWIR algorithm  
214 switches between the NIR and SWIR (generally between 1200 and 2100 nm) schemes for  
215 removing atmospheric contribution in non-turbid and turbid waters, respectively, being  
216 adapted for both conditions in the same scene. The modified NIR-SWIR correction, on the  
217 other hand, was proposed by Aurin et al. (2013) waters. This model works similarly to the  
218 NIR-SWIR algorithm, but the SWIR bands were smoothed by a 3x3-pixel filter before the  
219 atmospheric correction procedure to avoid the low SNR (signal-to-noise ratio) impact (only  
220 for MODIS sensor). The default masks were slightly modified, High-light mask was  
221 disabled while the stray-light mask enabled. Then, two L2gen schemes were performed for  
222 each scene, one using the standard NIR correction and another a SWIR forced correction,  
223 which was later merged based on a threshold  $R_{rs}(645)$  value of  $0.01 \text{ sr}^{-1}$ . Lastly, the MUMM  
224 algorithm was developed for eliminating aerosol contribution over moderate turbid waters  
225 based on the assumption of spatial homogeneity of two NIR band ratios (same as above) for  
226 aerosol and water-leaving reflectances. The same mask configuration was used for the all  
227 models.

### 228 3.3.2. Match-up exercises

229 The match-up procedures were conducted following the same logic as Garcia et al.  
230 (2005), Goyens et al. (2013), and Jamet et al. (2011) works, based on Bailey and Wang  
231 (2001) protocol. Before the coincident reflectances collected *in situ* and satellite-derived  
232 could be compared, some exclusion criteria were applied. Firstly, the reflectance data  
233 collected in a time interval greater than 2 hours from the satellite overpass were removed.  
234 Then, we calculated the average and the standard deviation of a 3-by-3 pixel window  
235 centered at the middle pixel (point location). The window where either more than 30% of  
236 the pixels were flagged or the standard deviation corresponded to more than 20% of the

237 average value were excluded. Additionally, the hyperspectral field measurements were  
 238 integrated over the spectral response function of the VIIRS (M5 and M7) and MODIS (B1  
 239 and B2) bands to obtain the band-weighted equivalent reflectances (Nechad et al., 2010b;  
 240 Zhang et al., 2010). The statistical metrics used here for evaluating the match-up accuracy  
 241 and uncertainty of each wavelength were: (1) Spearman's correlation coefficient (r), (2)  
 242 root mean squared error (RMSE), (3) mean absolute percentage error (MAPE), (4) Mean  
 243 Error or Bias. These metrics were calculated as:

$$RMSE_{\text{match-up}} = \sqrt{\frac{\sum_{i=0}^{n-1} (\rho_{\text{sat}} - \rho_{\text{in situ}})^2}{N}} \quad (2)$$

$$MAPE_{\text{match-up}} = \frac{1}{N} \sum_{i=0}^{n-1} \left| \frac{\rho_{\text{sat}} - \rho_{\text{in situ}}}{\rho_{\text{in situ}}} \right| \times 100 \% \quad (3)$$

$$Bias_{\text{match-up}} = \frac{1}{N} \sum_{i=0}^{n-1} \frac{\rho_{\text{sat}} - \rho_{\text{in situ}}}{\rho_{\text{in situ}}} \times 100 \% \quad (4)$$

244 Where N corresponds to the number of observations,  $\rho_{\text{in situ}}$  and  $\rho_{\text{sat}}$  are respectively the  
 245 field measured and the remotely sensed estimated  $\rho$ , respectively. The r formula is not  
 246 shown here for brevity.

### 247 3.4. TSM Model Development and Assessment

248 Linear regressions were performed between the *in situ*  $\rho$  and TSM under a variety  
 249 ranges to achieve the best fit with minimum errors. At the end of this process, we obtained  
 250 one model using the  $\rho(645)$  for MODIS/Aqua, and two others using the  $\rho(671)$  and  $\rho(745)$   
 251 and for VIIRS/SNPP. Polynomial models were built from red bands due to the observed  
 252 saturation for higher TSM concentrations, while the NIR band products gave rise to a linear  
 253 model.

254 We decided to develop an algorithm that selects the most sensitive relationship  
 255 between TSM and  $\rho$  without saturating the red band, an approach that has been used by  
 256 Novoa et al. (2017). As a final result, we obtained a unique transitional algorithm that  
 257 blends the  $\rho(\text{red})$  and  $\rho(\text{NIR})$  models for estimating the TSM concentration. The next step

258 consisted in determining the red-to-NIR switching points where these models would be  
 259 merged. For that, *in situ* measurements of  $\rho(\text{red})$  and  $\rho(\text{NIR})$  were compared and a  
 260 logarithmic function was used to fit them. Once the curve was settled, the saturation point  
 261 of the red band was determined by finding the x and y values where the first derivative was  
 262 equal to 1, that is, the middle point between a completely horizontal (complete saturation) and a  
 263 completely vertical line. The same procedure occurred for the 95% confidence level curves.  
 264 For  $\rho(\text{red})$  values below the lower confidence curve, the linear model using the red bands  
 265 was applied, while for values above the upper confidence curve, the NIR linear model was  
 266 used. Finally, for values inside this range, a weighed model between the red and NIR  
 267 models was used to ensure a smooth transition between the results. Detailed information  
 268 about this method and all formulas are described in Novoa et al. (2017).

269 The statistical metrics used here for evaluating the accuracy and uncertainty of each  
 270 model were the (1) coefficient of determination ( $R^2$ ), the (2) root mean squared error  
 271 (RMSE), the (3) mean absolute percentage error (MAPE), and the (4) Mean Error or Bias.  
 272 These metrics were calculated as follows:

$$RMSE_{TSM} = \sqrt{\frac{\sum_{i=0}^{n-1} (\hat{y}_i - y_i)^2}{N}} \quad (5)$$

$$MAPE_{TSM} = \frac{1}{N} \sum_{i=0}^{n-1} \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (6)$$

$$Bias_{TSM} = \frac{1}{N} \sum_{i=0}^{n-1} \frac{\hat{y}_i - y_i}{y_i} \times 100\% \quad (7)$$

273 where N corresponds to the number of observations,  $y_i$  and  $\hat{y}_i$  are respectively the  
 274 measured and the predicted TSM value of the *ith* element. The  $R^2$  formula is not shown  
 275 here for brevity.

276 The present calibration dataset could not be divided into training and test sets due to  
 277 its restricted number of match-ups, considering this fact all the metrics were computed  
 278 using a K-fold cross-validation (CV) method, which splits the actual set of observations  
 279 into k smaller sets, then the best fit function is tuned using k-1 folds as training sets, and the

280 left fold is used as “unseen data” to validate the model. The number of k folds was  
281 determined based on the size of the datasets (number of match-up points for each model  
282 and atmospheric correction method) and the best metrics computed for both training and  
283 test sets. Then, the values presented here consist of the average and standard deviation of  
284 each statistical metric computed for all k test set (a total of 5 k folds were evaluated). A  
285 similar approach has been used by Petus et al. (Petus et al., 2010).

286 For comparison purposes, we also performed the recalibrated semi-analytical  
287 algorithm formulated by Nechad et al. (2010a), which calculates the TSM concentration  
288 over turbid waters with great accuracy, according to many studies (Di Polito et al., 2016;  
289 Knaeps et al., 2015; Niencheski & Windom, 1994; Novoa et al., 2017; Tavora et al., 2019;  
290 Vanhellefont & Ruddick, 2015).

### 291 **3.5. Validation of the resulting TSM algorithm**

292 After this calibration process, supplementary *in situ* TSM measurements (36 match-  
293 ups) with concurrent satellite-derived TSM were used for validation purposes. The  
294 additional data were collected during the same campaigns described in Section 3.1. and  
295 were not included in the previous algorithm tuning process because no radiometric  
296 measurements have been performed. The same methodology described in Section 3.2.2 was  
297 applied for the satellite-derived TSM comparisons, except for the tolerance time from  
298 satellite overpass. In this case, we considered a 3-hour interval, although the points within  
299 this range corresponded to only 7% of the entire dataset. The rest of the match-ups lied on  
300 the recommended 2-hour interval. The same statistical metrics explained in the previous  
301 section were used for assessing the algorithm performances under different atmospheric  
302 corrections.

303 **4. Results and Discussion**

304 **4.1. Optical complexity and variability in the EPL**

305 The IOPs, physical variables, and optically active constituents presented a wide  
 306 range over the period of sampling. Table 2 shows their values for the entire region, and for  
 307 stations placed inside and outside the EPL water body (see Figure 1). Overall, their values  
 308 are in good agreement with the data collected by Rodrigues (2014), who used the same  
 309 sampling strategy as the present 2014-2015 datasets. Salinity and temperature ranges  
 310 represent well the physical conditions within the lagoon, where both freshwater, brackish  
 311 and salt waters may be found, as well as waters colder than 12 °C in winter and warmer  
 312 than 20°C during the summer. The temperatures inside and outside the lagoon were very  
 313 similar, while the average salinity differed between two areas. The lagoon showed an  
 314 average salinity of 7, and the adjacent coastal waters had an average of 26. Similar values  
 315 of maxima and minima indicate the water exchange is due to either the entrance of the  
 316 saltwater or the plume discharge (Möller & Castaing, 1999). Despite these occasional  
 317 saltier conditions, the inner lagoon tends to be less saline than adjacent coastal waters.

**Table 2.** Mean, standard deviation, maximum, and minimum values of the physical variables, IOPs and active optical constituents with their respective units. Results are also divided in subregions: inner and outer lagoon. The mouth of the channel (Figure 1) was defined as the limit of the lagoon. All variables, include values in the water column, except TSM which was measured only at surface.

	All regions		Inner lagoon		Adjacent Waters	
	Mean	Min – Max	Mean	Min – Max	Mean	Min – Max
T (C°)	19.41±0.27	11.20 – 24.21	20.15±0.32	15.44 – 23.78	19.43±0.52	15.40 – 24.21
S	11.26±2.29	0.00 – 28.77	7.84±2.29	0.00 – 29.89	26.35±2.73	0.01 – 32.73
CDOM (ppb QSE)	26.29±6.54	0.03 – 120.68	33.53±8.77	0.02 – 96.38	10.51±3.74	0.14 – 120.68
CHL-a (µg.L <sup>-1</sup> )	2.11±0.53	0.00 – 14.45	1.88±0.63	0.01 – 14.45	1.91±0.69	0.00 – 11.60
TSM (mg/L)	29.83±22.49	2.26 – 108.00	39.90±21.53	11.70 – 108.00	17.68±17.20	2.26 – 64.50
bbP(532) (m <sup>-1</sup> )	0.13±0.03	0.00 – 0.21	0.14±0.04	0.00 – 0.21	0.11±0.04	0.01 – 0.21
bbP(660) (m <sup>-1</sup> )	0.08±0.01	0.00 – 0.12	0.08±0.01	0.00 – 0.12	0.07±0.02	0.01 – 0.12
c(412) (m <sup>-1</sup> )	9.74±0.66	1.48 – 29.52	12.51±1.46	2.01 – 23.02	7.80±2.27	0.70 – 18.33
c(532) (m <sup>-1</sup> )	9.84±0.53	1.49 – 29.77	12.63±1.42	2.02 – 28.76	8.31±2.04	0.59 – 33.82
c(676) (m <sup>-1</sup> )	9.02±0.52	1.28 – 30.43	11.22±1.25	1.70 – 24.05	6.76±1.84	0.32 – 29.46
c(715) (m <sup>-1</sup> )	7.15±0.53	0.38 – 27.89	9.44±1.22	0.75 – 19.49	5.22±1.54	0.00 – 29.27

318 Regarding the concentration of the optically active constituents for the whole  
 319 dataset, the CHLa concentration presented a maximum concentration of 14.45 µg/L, while

320 TSM and CDOM concentrations reached over 100 mg/L and 100 ppb. The TSM  
 321 concentration exhibited the largest standard deviation among the constituents,  
 322 corresponding to about 75% of its mean concentration, the greatest spatial variability in  
 323 comparison to the other observed constituents. Comparing the lagoon and adjacent coastal  
 324 waters, we found that CDOM concentration is tripled, and TSM concentration is doubled  
 325 within the lagoon, while the CHLa concentration remains almost the same. Based on these  
 326 data, we can assume that the continental input influences the optical constituents dynamics  
 327 in the EPL and coastal environments, what was already expected.

**Table 3.** Pearson Correlation analysis between the IOPs, the optically active constituents and conservative properties of the entire water column (p-value<0.5). The values highlighted are the greatest encountered for each column.

	<b>T</b>	<b>S</b>	<b>CDOM</b>	<b>CHLa</b>	<b>b<sub>bp</sub>(532)</b>	<b>b<sub>bp</sub>(660)</b>	<b>c(412)</b>	<b>c(532)</b>	<b>c(676)</b>	<b>c(715)</b>
<b>T</b>										
<b>S</b>	-0.68									
<b>CDOM</b>	0.66	-0.8								
<b>CHLa</b>	-0.72	0.56	-0.47							
<b>b<sub>bp</sub>(532)</b>	0.29	-0.62	0.75	-0.32						
<b>b<sub>bp</sub>(660)</b>	0.27	-0.6	0.72	-0.32	0.98					
<b>c(412)</b>	0.5	-0.74	0.66	-0.44	0.76	0.77				
<b>c(532)</b>	0.48	-0.7	0.64	-0.46	0.74	0.76	0.99			
<b>c(676)</b>	0.48	-0.67	0.62	-0.47	0.73	0.74	0.98	1		
<b>c(715)</b>	0.48	-0.67	0.61	-0.47	0.72	0.74	0.98	0.99	1	

328 Concerning the inherent optical properties variability, the particulate backscattering  
 329 coefficient revealed similar ranges at 532 and 660 nm, being slightly greater at the green  
 330 bands for both areas, without any significant difference. The beam attenuation coefficient  
 331 ( $c(\lambda)$ ), on the other hand, evinced a decreasing tendency towards the longer wavelengths  
 332 (Table 2), contrary to what is observed in typical oceanic regions, where the attenuation at  
 333 blue wavelengths is lower than other visible wavelengths. The pattern observed in this  
 334 study is usually observed in coastal waters (Kirk, 1984; Kitchen et al., 1982; Whitlock et  
 335 al., 1981). It is worth noting that the attenuation coefficients at all wavelengths decrease

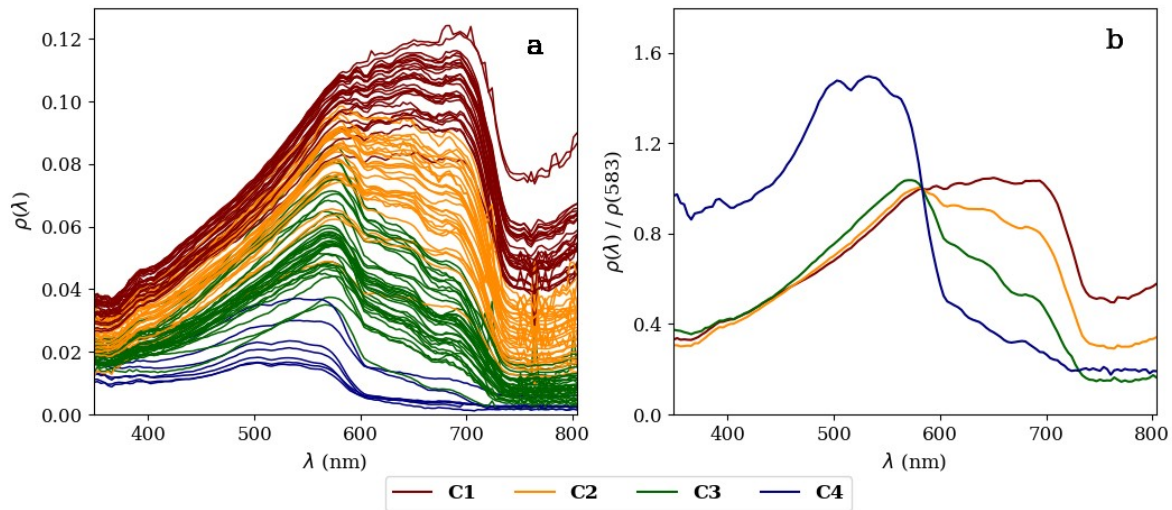
336 seaward, evidencing a slightly lower contribution of TSM and CDOM concentrations  
337 outside the lagoon. Even though, both decreasing patterns typify classical Case 2 water  
338 profiles.

339         The Pearson correlation analysis (Table 3) demonstrated a moderate inverse  
340 correlation between the temperature and salinity, which was already mentioned above when  
341 outside stations presented higher (lower) average values of salinity (temperature), while the  
342 opposite situation occurred inside the lagoon. Salinity also showed inverse correlations with  
343 all optical variables, especially with CDOM, as expected IOCCG, 2008; Slonecker et al.,  
344 2016). The CDOM concentration shows positive (moderate to low) correlations with  
345 temperature, particulate backscattering, and attenuation coefficients. In general, CHLa  
346 concentration displays a low negative correlation with the IOPs. TSM concentration is not  
347 shown here because it has been measured only at surface while this analysis was performed  
348 over the entire water column using the data acquired by the profiler instruments.  
349 Attenuation coefficients have high correlations with each other. Higher correlations  
350 between backscattering and attenuation in blue bands indicate that the absorption in these  
351 bands (mostly due to CDOM) leads the spectrum peak displacement towards the green and  
352 red bands (Figures 2 and 4), since the reflectance is directly proportional to backscattering  
353 and inversely proportional to absorption (Gould et al., 1999).

354         In order to evaluate how the IOPs influenced the spectral reflectance, each  
355 individual *in situ*  $\rho$  spectra were grouped using a K-means clustering analysis, as described  
356 in Section 1.4. Four clusters were found, hereinafter referred to as Class 1 to Class 4 (C1-  
357 C4). Overall, the whole spectra presented Case 2 waters characteristics (IOCCG, 2000).  
358 The first two classes (1 and 2) have a distinctive spectral shape of waters with high  
359 sediment and CDOM loads. The signal intensity in Class 3 started to decrease from 560 nm  
360 and had the lower values in NIR bands, its spectral shape is usually referred to waters with  
361 high to moderate concentration of terrigenous materials, and some contribution of  
362 phytoplankton, as the profiles collected at same point suggest. Lastly, the fourth class is the  
363 one that comes closest to Case 1 waters spectral shape, but due to its slightly high green  
364 signal, it is classified as a Case 2 water as well, with moderate chlorophyll and sediment



365 concentrations. This spectral pattern is also verified on other coastal and estuarine areas  
366 (Doxaran et al., 2004; Knaeps et al., 2015; Vantrepotte et al., 2012).




**Figure 2.** Cluster K-means analysis over each *in situ* spectra collected (a) and the average normalized reflectance of each class (b).

367 To better understand how these classes are influenced by the active optical  
368 constituents, a Principal Components Analysis (PCA) was carried out (Figure 3).  
369 Regrettably, class 4 is not shown on these plots due to the absence of data collected in  
370 concurring time. The PCA biplot showed in Figure 3 elucidates how each optical  
371 constituent explains the total variance of reflectances. In our results, all variance in the  $\rho$   
372 dataset can be explained by two principal components: the first one – or mode 1 on the x-  
373 axis – is responsible for 64.4% of the total variance in the dataset, and the second – mode 2  
374 on the y-axis – resolves 35.6%. The CDOM and TSM concentrations correspond together  
375 to 98% of variability in mode 1 (CDOM= 45.3% and TSM=42.2%), whereas mode 2 has a  
376 greater contribution of the CHLa (68%), followed by the TSM contribution of 26%


377 According to PCA results, the variance of spectral signatures of Class 1 was less  
378 correlated with chlorophyll concentration, being mostly described by CDOM and TSM  
379 (mode 1). Most stations belonging to this class had association with CDOM concentration,

380 whilst only a few samples were highly correlated with TSM. Class 2 had sparser behavior,  
381 being described by both dimensions and optical constituents, although it is mostly  
382 associated with TSM and CHLa concentrations. This group had the most heterogeneous  
383 composition among the classes. Finally, the Class 3 showed better correlation with CDOM  
384 and CHLa concentrations, being also described by both modes.



**Figure 3.** PCA showing the total variance of  $p$  described by the optical constitution of the samples. Large size markers represent the mean point of each class.

385 In summary, all statistical analyses presented in this section highlight the co-  
386 dominance of CDOM and TSM concentrations over/in the optical components of the field  
387 measurements, suggesting the great importance of continental input in the region as a  
388 whole. Nevertheless, for further studies, it is worth to keep in mind that the spectral  
389 response of these waters might be dependent on both TSM and CDOM concentrations. The  
390 *in situ* reflectance spectrum and the respective TSM concentration are represented in  
391 Figure 4b, which corroborates with previous clustering analysis (Figure 2). An overall  
392 increasing gradient of TSM concentration is observed from Class 4 to 1. Class 4 conferred  
393 the lower TSM concentrations (from 0 to 20 mg/L), the Class 3 presented concentrations  
394 varying between 10 to 40 mg/L, while Classes 2 and 1 exhibited moderate to high TSM  
395 concentrations (between 50 and 100 mg/L).



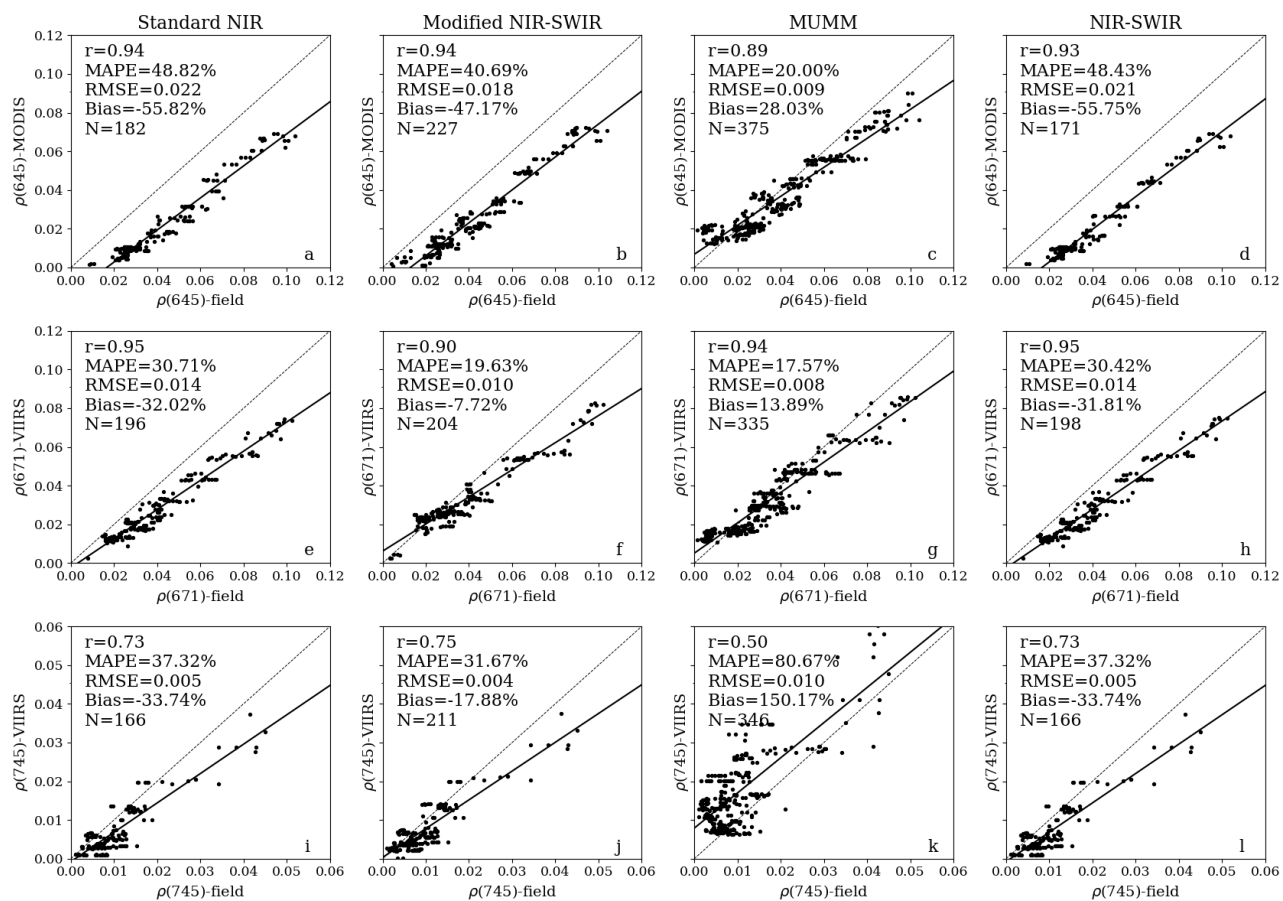
**Figure 4.** (a) The statistical metrics (R-squared, MAPE, and Bias), the solid line represents the R-squared, the dashed line refers to the Bias, and the dotted line refers to the MAPE. (b) The TSM concentration for each individual spectrum collected on field for each linear regressions performed between TSM concentration and  $\rho$  in 137 bands. The vertical lines correspond to each center-band analyzed in this study for algorithms development –  $\rho(645)$ ,  $\rho(671)$ , and  $\rho(745)$ .

396           Despite the co-dominance between TSM and CDOM concentrations in the optical  
 397 components of most samples, there is a direct relationship between the sediment load and  
 398 the increase in radiance intensity, mainly in red and NIR bands – the most sensitive interval  
 399 to TSM concentration variations. Unfortunately, the spectroradiometer does not measure  $\rho$   
 400 in larger wavelengths ( $>804$  nm), where this sensitivity tends to be even higher, especially  
 401 for highly turbid waters (Doxaran et al., 2004; Knaeps et al., 2015; Vanhellemont &  
 402 Ruddick, 2015). Even so, in the last band collected by the instrument,  $\rho$  appear to be again  
 403 responsive to changes in TSM concentration. Linear regressions were computed to evaluate  
 404 how well *in situ*  $\rho$  predicted TSM concentration in each wavelength (Figure 4b). As  
 405 expected, the result identified the most sensitive interval (590-700 nm) as the best predictor  
 406 as well, where higher coefficients of determination ( $>0.8$ ) and small relative errors ( $<30\%$ )  
 407 were found. The overall bias remained positive and less than 20%, especially within 550-  
 408 700 nm. Outside this range, the errors tended to increase and the r-squared decreased,  
 409 especially for wavelengths between 740 – 800 nm. These results are consistent with

410 previous studies (J. Acker et al., 2005; Larouche & Canada, 2003; Van Der Woerd &  
411 Pasterkamp, 2004).

## 412 **4.2. Validation of Atmospheric Corrections**

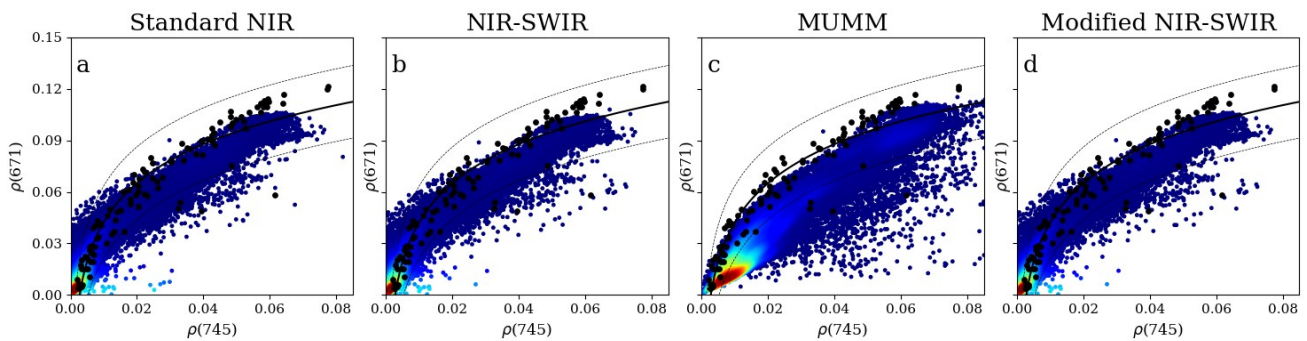
413 The atmospheric correction algorithms validation for the 645, 671, and 745 bands  
414 was done by comparing spectral reflectances collected *in situ* convoluted to the sensors  
415 bands with the coincident reflectance derived from MODIS and VIIRS sensors (Figure 5).  
416 Linear models were carried out for evaluating which atmospheric correction had better  
417 performance. According to Figures 5a to 5d, the comparison with MODIS-derived  $\rho(645)$   
418 showed higher correlation coefficient ( $r$ ) values for standard and modified NIR-SWIR and  
419 iterative NIR corrections (Figures 5a, 5b, and 5d), although MUMM correction presented  
420 lower errors and less biased results (Figure 5c). All bias values remained negative,  
421 demonstrating an underestimation of the satellite-derived  $\rho$ , except for the one calculated  
422 from MUMM's products. The performances of linear models of VIIRS-derived water  
423 leaving reflectances are displayed in the last two rows of Figure 5. Lower absolute and  
424 normalized error is observed in comparison with MODIS results, although the same  
425 underestimation pattern is observed for the NIR and NIR-SWIR algorithms (Figure 5a, 5b  
426 and 5d). The MUMM correction presented better statistics for both red bands (Figures 5c  
427 and 5g), followed by the modified NIR-SWIR model (Figures 5b and 5f). The iterative NIR  
428 and the standard NIR-SWIR corrections tended to underestimate  $\rho$  more than the other  
429 models, and thus generating the highest errors. The match-ups between the VIIRS-derived  
430  $\rho(\text{NIR})$  and the *in situ* hyperspectral data showed higher normalized errors and lower  
431 correlation coefficients compared to  $\rho(\text{red})$  from the same sensor (Figures 5i, 5j, 5k, and  
432 5l). In contrast to previous bands, the MUMM corrected products showed the worst results  
433 and poorer linearity (Figures 5c and 5k), while the modified NIR-SWIR algorithm  
434 produced better performance (Figure 5j). The iterative NIR and standard NIR-SWIR  
435 presented quite similar results for all sensors and bands analyzed here.



**Figure 5.** Linear regressions between *in situ* and the satellite-derived  $\rho$ . The first column (a,e,i) represents  $\rho$  derived using the standard NIR correction algorithm, the second (b,f,j) using the adapted NIR-SWIR, the third (c,g,k) using the MUMM correction, and the fourth (d,h,l), the standard NIR-SWIR. First row (a,b,c,d) corresponds to the MODIS-derived  $\rho(645)$ , the second (e,f,g,h) corresponds to the VIIRS-derived  $\rho(671)$ , and the third (i,j,k,l) to the VIIRS-derived  $\rho(745)$ . The dashed line refers to 1:1 and the thick black line to linear fitting.

436            These uncertainties produced for both sensors may have been caused by the coarse  
437 spatial resolutions (250-m and 750-m), that might not resolve the local reflectance  
438 variability found on each scene. Thus, to overcome or diminish this spatial problem, a red-  
439 to-NIR band comparison was made using satellites and field spectral reflectances, and we  
440 also superimposed on the same plot the logarithmic fit between  $\rho(\text{red})$  and  $\rho(\text{NIR})$   
441 described on Section 3.3 (Figure 6). These graphs were done for each cruise, but only the  
442 2018-2019 cruises are shown because of their greater variability in reflectance. Due to the  
443 absence of a correspondent NIR band from the MODIS sensor with the HyperSAS, only the

444 results from VIIRS are shown here. Primarily when NIR and NIR-SWIRs corrections were  
 445 compared, only a small percentage of points are located outside the confidence intervals,  
 446 although the underestimation of  $\rho$ , illustrated in Figure 5, is well evinced. The products  
 447 from MUMM correction displayed a forward displacement towards the lower confidence  
 448 line due to the overestimation of  $\rho$ . In this case, however, most of the pixels were placed  
 449 outside the confidence interval due to the uncertainties in estimating  $\rho(\text{NIR})$ , as reported in  
 450 Figure 5. Despite the misestimations from all atmospheric corrections, a general good  
 451 overlap between satellite pixels and the logarithmic saturation model was observed,  
 452 specially when NIR and NIR-SWIR (modified and standard) corrections were applied. It is  
 453 important to highlight that the same overlapping pattern was encountered for the other  
 454 cruises (2014-2016), reinforcing the effectiveness of atmospheric corrections over the  
 455 region despite the relatively large normalized errors from the linear regressions between the  
 456 coincident  $\rho$  points.



**Figure 6.** Red-to-NIR band comparison between *in situ* data from 2018-2019 campaigns (black dots) and VIIRS-derived  $\rho$  from all the scenes (colored dots), the black solid line corresponds to the *in situ* logarithmic fit function, and the dashed lines to the 95% confidence level curves. The (a) first column represents  $\rho$  derived using the standard NIR correction algorithm, (b) the second using the adapted NIR-SWIR, (c) the third using the MUMM correction, and (d) the fourth, the standard NIR-SWIR.

457 In addition to all these procedures, an inter-comparison between the different  
 458 atmospheric correction was performed (Figures S1 and S2). As expected, good agreement  
 459 was observed between NIR, NIR-SWIR, and modified NIR-SWIR corrections for both  
 460 sensors, since the data had similar distributions. The comparisons between these  
 461 atmospheric products with MUMM-derived  $\rho$ , notwithstanding, emphasize the


462 overestimation expressed above, especially when reflectance values in red and NIR bands  
463 were lower than 0.01 and 0.05, respectively. Similar patterns were found for  $\rho(\text{NIR})$ , but  
464 not shown here. The MUMM algorithm was formulated for moderately turbid waters,  
465 hence, this model is only valid for maximum reflectance values of 0.044 and 0.02 for 748  
466 and 869 nm, respectively (Ruddick et al., 2000a). Therefore, one would expect this  
467 overestimation of the MUMM products before achieving these limits, as shown in Figures 6  
468 and other studies (Chaichitehrani et al., 2018; Ody et al., 2016). When this ceiling is  
469 reached, the  $\rho(748):\rho(869)$  ratio becomes non-linear, then an overestimation of the aerosols  
470 and consequent underestimation of water-leaving reflectances are expected (Ruddick et al.,  
471 2000a). Even though some outcomes remain overestimated, the distribution of pixel values  
472 becomes more dispersed, demonstrating the ineffectiveness of MUMM correction over  
473 turbid waters. The possible causes of these overrated values is still unknown, albeit either  
474 partial land-sea, as well as cloudy pixels or inhomogeneities in sediment type (size and  
475 composition) could be potential causes (Ruddick et al. 2000). Furthermore, the lower  
476 reflectance values produced by the other atmospheric corrections could be due to either an  
477 overestimation of aerosol contribution from NIR/NIR-SWIR methods or the land  
478 reflectance effect in nearshore pixels (Novoa et al., 2017). Moreover, lower SNR of the  
479 MODIS-250m resolution bands may also explain some incongruous values shown above.

#### 480 **4.3. TSM model's assessment**

481 Figure 7 illustrates the three models created from the sensor-convoluted *in situ*  $\rho$ .  
482 The MODIS and VIIRS red bands derived models are shown in the left panel (Figure 7a).  
483 In both red bands, a polynomial fit provided the best results since  $\rho(645)$  and  $\rho(671)$   
484 showed a non-linear behavior with increasing TSM concentrations. This mostly occurs due  
485 to the saturation of these bands when the load of the suspended particles increases. Other  
486 studies reported the same situation (Knaeps et al., 2012, 2015; Novoa et al., 2017; Zhang et  
487 al., 2010). The saturation starts when TSM concentrations overcome 37-40 mg/L in our set  
488 of *in situ* measurements, and the sensitivity of the red bands diminishes. The VIIRS-



489 convoluted  $\rho(\text{NIR})$ , on the other hand, presented a linear pattern demonstrating its greater  
 490 sensitivity to high TSM concentrations (Figure 7b).



**Figure 7.** (a) Scatter plots of the convoluted  $\rho(\text{red})$  versus TSM concentration. Red dots represent the in situ weighted  $\rho(645)$ , and green dots the  $\rho(671)$ . (b) Scatter plot of the convoluted  $\rho(745)$  versus TSM concentration. The solid lines represent the polynomial and linear best fits for each band. See Table 4 for details.

491 The statistical metrics from each algorithm are shown in Table 4, as well as each  
 492 derived formula. Overall, as shown in Table 4, all models presented good results, especially  
 493 the polynomial red ones that showed quite similar performances for both convoluted bands.  
 494 The algorithm created from the MODIS convoluted  $\rho(645)$  had slightly lower errors  
 495 (MAPE=29% and bias=11%) and a greater determination coefficient ( $R^2=0.9$ ), although  
 496 also presented a higher positive bias compared to the VIIRS convoluted  $\rho(671)$  (6%). The  
 497 convoluted  $\rho(745)$ , on the other hand, showed the lower determination coefficient and the  
 498 highest errors, mainly the absolute percentage error that reached 45%. Nevertheless, even  
 499 these larger errors are still within an acceptable range comparing to other TSM algorithms,  
 500 as demonstrated in some studies that achieved either similar or yet worse results (Han et al.,  
 501 2016; Nechad et al., 2010b; Siswanto et al., 2011; Zhang et al., 2010). In these works, the  
 502 relative bias ranged from -15% to 49%, and the relative absolute percentage error from 12%  
 503 up to 82%. According to Petus et al. (2010), errors less than 30% are considered weak,  
 504 while those errors less than 50% are moderate. Thus, our models were accurate to predict  
 505 the TSM concentration over the present dataset.



**Table 4.** R-squared, mean absolute percentage error, root mean squared error, and bias computed from the regressions between the *in situ*  $\rho$  convoluted to MODIS and VIIRS bands and the TSM concentrations. The resulting model from each fit is elucidated

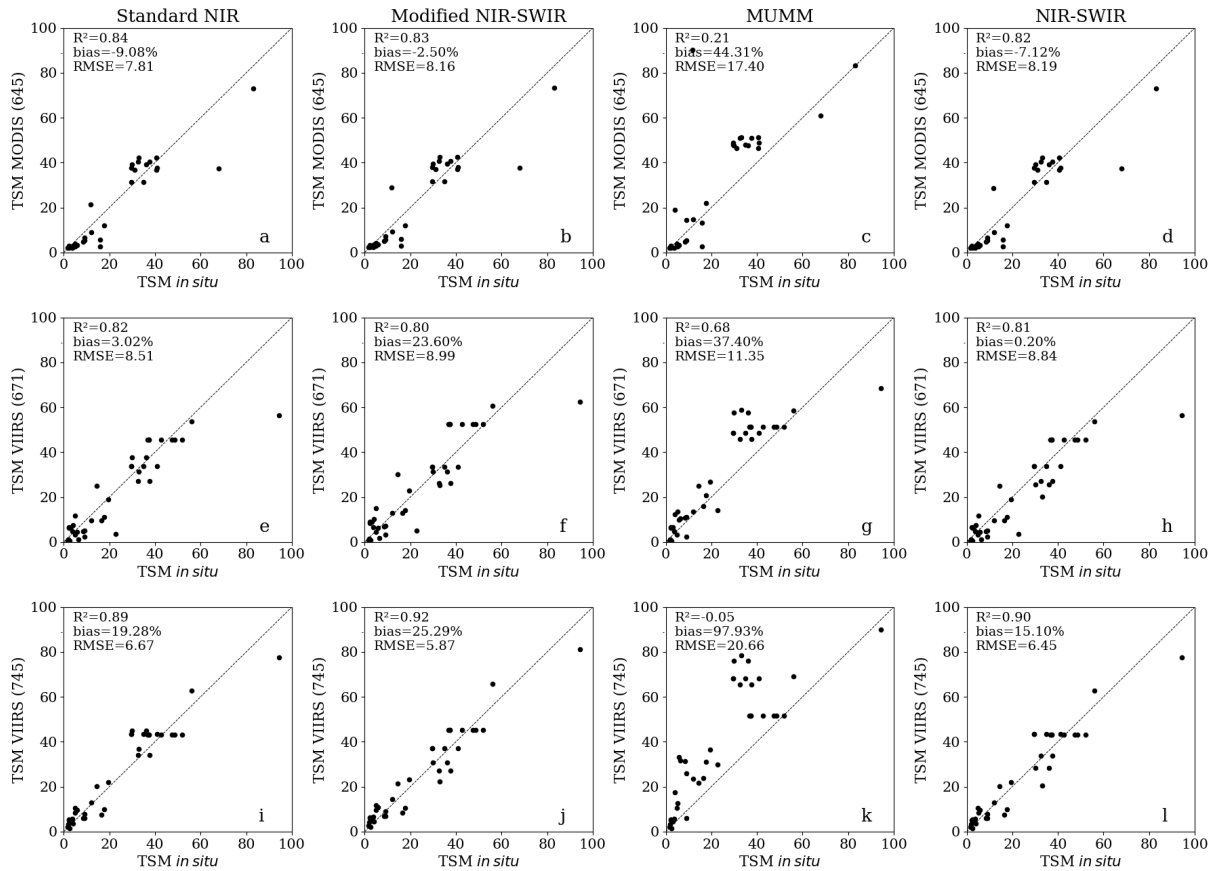
	<b>Model</b>	<b>R2</b>	<b>MAPE (%)</b>	<b>RMSE</b>	<b>Bias (%)</b>	<b>N</b>
<b><math>\rho(645)</math></b>	$6572.\rho(645)^2+45.\rho(645)+2$	0,91	28,88	6,39	11,34	53
<b><math>\rho(671)</math></b>	$6017.\rho(671)^2+145.\rho(671)+0.4$	0,91	25,48	6,43	5,86	53
<b><math>\rho(745)</math></b>	$1291.\rho(745)-0.4$	0,89	45,82	7,17	37,93	53

506 All statistical results and scatterplots from the validation process (satellite-derived  
507 TSM versus *in situ* TSM) are summarized in Table 5 and Figure 8. The polynomial model  
508 created from the MODIS convoluted  $\rho(645)$  showed a better performance for the NIR and  
509 NIR-SWIR based products (Figure 8a, 8b, and 8d). Although the iterative NIR algorithms  
510 provided the highest determination coefficient and the lowest MAPE and RMSE values, the  
511 bias was quite higher (-9%) compared to the other correction schemes. The standard and  
512 modified NIR-SWIR corrections also provided good metrics and had equivalent  
513 performances. The RMSE from these three atmospheric corrections ranged from 7.8 to 8.2  
514 mg/L, which corroborates with results found by Nechad et al. (2010b). The MUMM  
515 correction, on the other hand, demonstrated the worst performance (Figure 8c) once its  
516 errors doubled. Although this latter correction has presented the best atmospheric match-  
517 ups (Figures 5c), it also showed the same scattered pattern when plotted onto the closest *in*  
518 *situ* reflectances (red-to-NIR band comparison), as illustrated on Figure 6c. It might have  
519 lead this greater offset of TSM concentrations, inducing larger errors. It is also worth  
520 pointing out that the bias of the standard NIR, NIR-SWIR, and modified NIR-SWIR  
521 products followed the same negative trend as seen in atmospheric match-ups (Figures 6a,  
522 6b, and 6d), but thank the slight overestimation of the polynomial red model these  
523 underestimations became weaker. The contrary is valid for the MUMM corrected  $\rho$ , which  
524 presented the most positively biased results.

525 Even though the higher relative errors, good results were achieved when the TSM  
526 algorithms were applied to VIIRS products, especially for  $\rho$  in the NIR interval (Figures 8i  
527 to 8l). Regarding the red bands, the NIR-corrected  $\rho(671)$  generated the best TSM estimates  
528 and lower errors, right after the standard NIR-SWIR correction (Figures 8e and 8h). Both

529 corrections had very similar performances and lower negative biases. Despite presenting  
530 quite higher errors and more biased results, the modified NIR-SWIR correction also  
531 provided a good capacity for predicting TSM concentration. Again, the MUMM corrected  
532 products exhibited poor performance and highly biased estimates in comparison to the other  
533 algorithms. These results seemingly reflected a combined effect of the correlation  
534 coefficients ( $r$ ) and biases presented in Section 4.2. (Figure 5). Even though higher relative  
535 and absolute errors were associated to the standard NIR and NIR-SWIR corrections during  
536 the match-up exercise, higher correlations were also observed with *in situ*  $\rho$  ( $r=0.95$ ), and  
537 probably due to this fact, along with the slight overestimation of the TSM polynomial  
538 model, these atmospheric corrections showed better performances.

539         The TSM concentrations derived from the VIIRS  $\rho(745)$  also presented a good  
540 agreement with the measurements of the validation dataset despite the higher biases found.  
541 Here, we found the best determination coefficient and lower errors when the linear NIR  
542 model was applied to the modified NIR-SWIR products, albeit the standard NIR-SWIR and  
543 NIR corrections also provided similar metrics. The root means square errors from these  
544 products were lower compared to the ones generated from the polynomial red models and  
545 ranged from 6.5 mg/L to 6.9 mg/L. Among all the other bands, the MUMM corrected  
546  $\rho(745)$  presented the worse performance validating the TSM concentrations, showing much  
547 larger errors. Once again, the validation results revealed a similar pattern to the correlation  
548 coefficients illustrated in Figures 5i to 5l. The larger values of bias could have occurred due  
549 to the overestimation induced by the linear NIR model presented in Table 4 (38%). The red-  
550 to-NIR band comparison displayed on Figures 6 also cohere with these results, since the  
551 NIR and NIR-SWIR based products presented the best atmospheric validations.



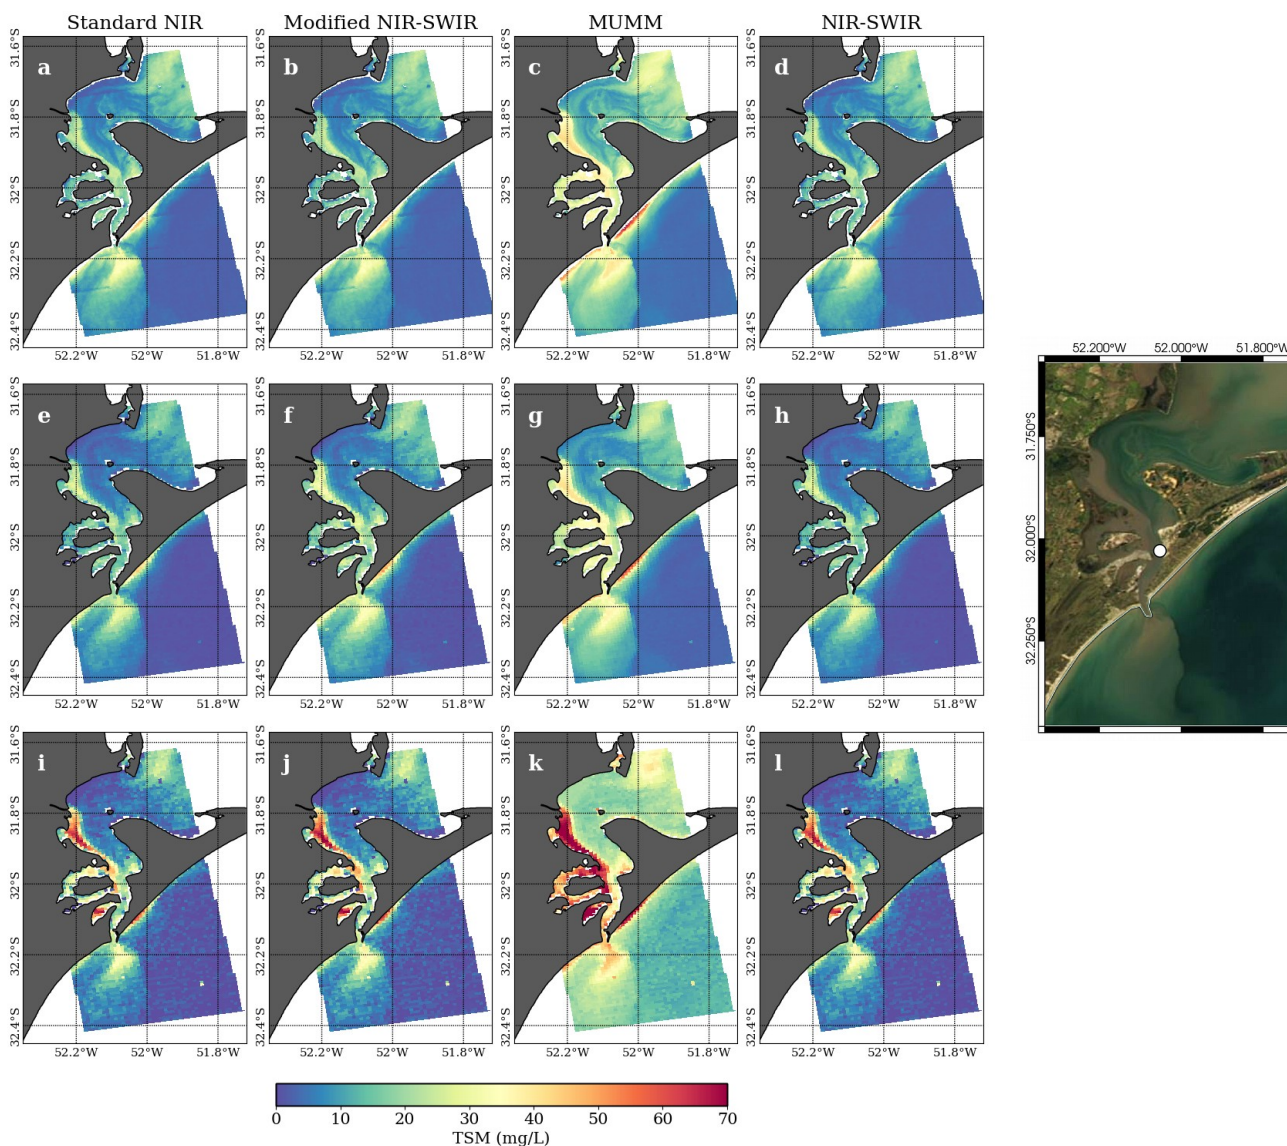
**Figure 8.** Satellite-derived versus *in situ* TSM concentrations. The first column (a,e,i) represents the TSM concentrations estimated from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR products, the third (c,g,k) using the MUMM derived  $\rho$ , and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to MODIS-derived  $\rho$ (645), the second (e,f,g,h) to VIIRS-derived  $\rho$ (671), and the third (i,j,k,l) to VIIRS-derived  $\rho$ (745).

552           The TSM concentration was also estimated through the semi-analytical algorithm  
553 proposed by Nechad et al. (2010a) using the same satellite-derived products, as shown in  
554 the last five columns in Table 5. When MODIS-derived  $\rho$  were selected as input for the  
555 semi-analytical model, the statistical metrics were inferior for almost all atmospherically  
556 corrected outputs but the MUMM. Small differences were found for MAPE and RMSE  
557 values (up to 5% and 1 mg/L, respectively), whereas the greatest discrepancies were  
558 observed for the bias (almost 20%). Similar patterns were observed for VIIRS products, but  
559 a general underperformance of the semi-analytical algorithm was verified, especially when  
560 MUMM products were tested. The relative mean absolute error increased over 20%, the  
561 root mean square error was only inferior when the modified NIR-SWIR algorithm was

562 used, and the bias reached up to 70% difference. The offsets between the *in situ* and  
 563 estimated TSM by the semi-analytical using the  $\rho(745)$  were even higher and all errors  
 564 increased in comparison to the proposed model, mainly the RMSE (from 1 to 14 mg/L).  
 565 The MUMM-corrected products noticeably generated the worse performance, and the  
 566 reasons for these inaccuracies may have been attributed by the errors in the atmospheric  
 567 correction, which evinced an unexpected overestimation (Figures 6, S1 and S2)

**Table 5.** R-squared, mean absolute percentage error, root mean squared error, and bias computed from the comparison of *in situ*, VIIRS/SNPP-derived TSM, and the recalibrated Nechad et al. (2010)-derived TSM. The metrics are calculated for all atmospheric corrections. The first four columns correspond to the proposed polynomial and linear models for calculating TSM concentration, the last four columns represent Nechad et al. (2010) models.

		Our models				Nechad (2010)				
Atmospheric Correction	R <sup>2</sup>	MAPE (%)	RMSE (mg/L)	Bias (%)	R <sup>2</sup>	MAPE (%)	RMSE (mg/L)	Bias (%)	N	
$\rho(645)$	Standard NIR	0,84	29,35	7,81	-9,08	0,80	34,26	8,72	-28,21	31
	Modified NIR-SWIR	0,83	31,21	8,16	-2,50	0,79	35,79	8,92	-26,74	31
	MUMM	0,21	67,82	17,40	44,31	0,33	64,83	16,08	22,54	31
	NIR-SWIR	0,82	31,31	8,19	-7,12	0,79	35,76	8,92	-26,72	31
$\rho(671)$	Standard NIR	0,82	44,10	8,67	-1,84	0,75	68,15	10,24	57,05	34
	Modified NIR-SWIR	0,81	45,94	8,92	16,68	0,80	64,52	9,24	49,61	34
	MUMM	0,68	60,73	11,60	34,22	0,15	105,46	19,00	101,41	36
	NIR-SWIR	0,81	44,92	9,02	-4,90	0,78	66,06	9,65	53,72	34
$\rho(745)$	Standard NIR	0,89	34,58	6,88	18,07	0,72	44,62	10,98	31,95	34
	Modified NIR-SWIR	0,92	33,04	5,97	23,27	0,88	37,04	7,34	18,23	34
	MUMM	-0,07	104,37	21,28	100,93	-1,98	141,87	35,52	137,84	36
	NIR-SWIR	0,90	33,93	6,64	13,52	0,78	41,43	9,80	26,02	34



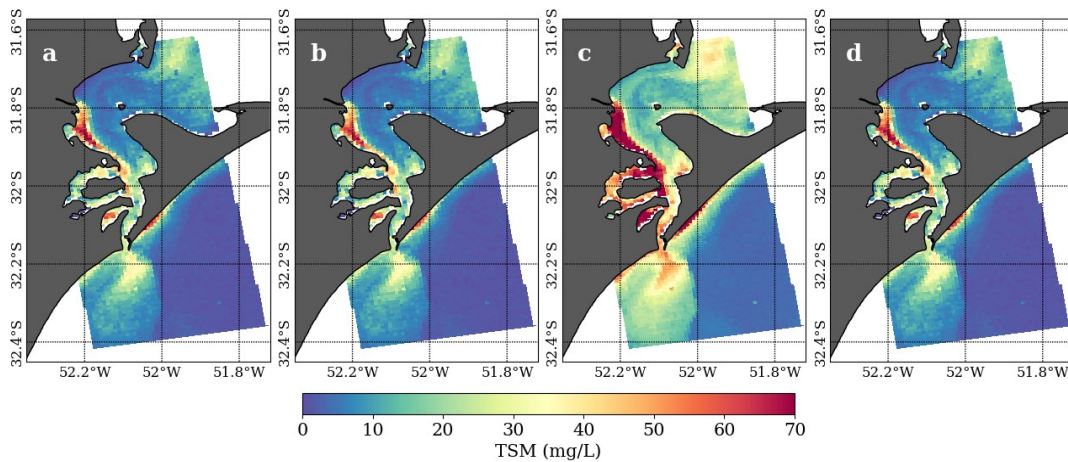
**Figure 9.** TSM maps estimated from MODIS and VIIRS products. The first column (a,e,i) represents the products from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR model, the third (c,g,k), the MUMM correction, and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to TSM maps estimated using the polynomial algorithm for MODIS-derived  $\rho(645)$ , the second (e,f,g,h), using the polynomial model for VIIRS-derived  $\rho(671)$ , and the third (i,j,k,l) using the linear model using VIIRS-derived  $\rho(745)$ . The scenes were acquired on 17 August 2019. The image on the right corresponds to the MODIS true-color composite scene acquired on the same day. The white dot on the image represents a TSM measurement collected by  $\pm 1$ hour from sensor overpass (20mg/L).

568                    Figure 9 shows the inter-comparison between the TSM maps generated from the  
 569 three models proposed using the MODIS and VIIRS bands, both scenes were acquired on

570 17 August 2018. The maps produced by the MODIS red bands showed analogous results  
571 when iterative NIR, standard and modified NIR-SWIR corrections were applied (Figures  
572 9a, 9b, and 9d). The MUMM corrected reflectances, on the other hand, showed a tendency  
573 to overestimate the TSM concentration (Figure 9c), cohering with previous regressions  
574 (Figures 8c) and the statistical metrics found in Table 5. The same situation was observed in  
575 the TSM maps generated from the  $\rho(671)$  (Figures 9e to 9h), but without the same spatial  
576 detail due to sensor resolution. Both the polynomial red models generated maps with  
577 maximum TSM concentration around 40 mg/L. The maps created from the  $\rho(745)$   
578 presented some noise interference over regions with low TSM concentration, mainly the  
579 NIR-SWIR-based products. This is well discussed by Vanhellemont and Ruddick  
580 (2015) and can be attributed to the synergistic effect of the natural noise in the SWIR  
581 bands, and the slight lower signal-to-noise ratio (SNR) of the  $\rho(671)$ . Despite the presence  
582 of these disruptions, the TSM maps showed good agreement with the previous ones created  
583 from the red bands, as well as presented greater TSM concentrations (around 60-70 mg/L).  
584 The right panel illustrated in Figure 9 refers to the true color composite image acquired  
585 from MODIS/Aqua on the same day, and the white dot assigns one of the TSM  
586 measurements used in the calibration process (20 mg/L). The great correspondence between  
587 the TSM maps and the true color image is noticeable, besides the reasonable agreement  
588 between the estimated and measured TSM concentrations.

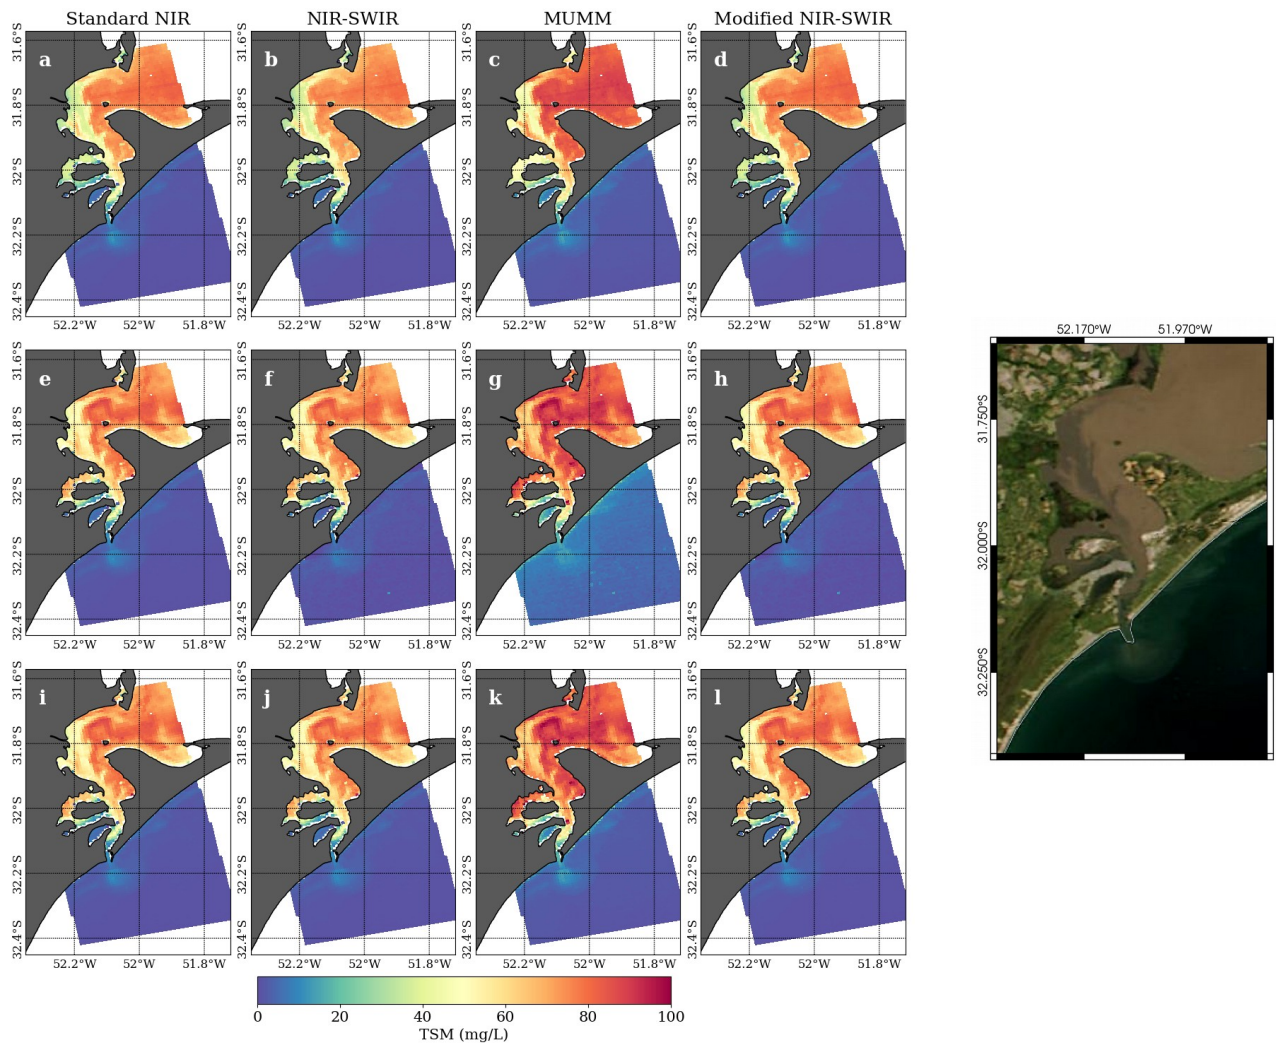
589         Despite the general condition of low-to-moderate TSM concentrations within the  
590 ELP region, many high river discharge events occur during the year and these  
591 concentrations easily overcome 40 mg/L, an interval where the  $\rho(\text{red})$  starts to saturate.  
592 Thus, the transitional algorithm proposed by Novoa et al (2017) was adapted and applied to  
593 our models, as demonstrates in Figures 10 and 11. Due to the absence of a correspondent  
594 MODIS-250m NIR band, this algorithm was only implemented in VIIRS bands. Figure 10  
595 represents the new TSM map for the same scene presented in Figure 9 (17 August 2018),  
596 and it is easily observed that the resulting product from the transitional algorithm preserved  
597 the best characteristics from both models: the higher TSM concentrations provided by the  
598 linear NIR algorithm, and the low noise interference verified in the  $\rho(\text{red})$  image.





**Figure 10.** TSM maps computed by the transitional algorithm (Novoa et al., 2017) applied to VIIRS-derived products. The first column (a) represents the TSM maps estimated from standard NIR corrected products, the second (b) using the modified NIR-SWIR products, the third (c) using the MUMM derived  $\rho$ , and (d) the fourth, the standard NIR-SWIR.

599            This situation is also well represented in images acquired on 30 November 2016  
600 (Figure 11), when TSM concentration within the lagoon is much higher than the outer  
601 regions. The first row corresponds to the linear red algorithm (Figure 11a to 11d), the  
602 second is referred to as the linear NIR model (Figure 11e to 11h), and the third represents  
603 the transitional model between these two bands (Figures 11i to 11l). The estimated TSM  
604 values from the polynomial red model reach their maximum at approximately 75 mg/L  
605 (Figures 11a to 11d). Contrarily, the concentrations estimated from the linear NIR algorithm  
606 were virtually higher, reaching up to 90 mg/L (Figures 11d to 11h). Again, the results of the  
607 transitional model maintained the higher TSM concentrations at the same time as the lower  
608 noise, especially in the coastal and plume regions (Figures 11i to 11l). In both cases, the  
609 transitional model produced a better output than each single-band model, and also provided  
610 a smooth transition between the two algorithms.



**Figure 11.** TSM maps estimated from VIIRS products. The first column (a,e,i) represents the TSM maps estimated from standard NIR corrected products, the second (b,f,j) using the modified NIR-SWIR products, the third (c,g,k) using the MUMM derived  $\rho$ , and (d,h,l) the fourth, the standard NIR-SWIR. First row (a,b,d,c) corresponds to TSM maps estimated using the polynomial red algorithm for VIIRS-derived  $\rho(671)$ , the second (e,f,g,h) to TSM maps estimated using the linear red model for VIIRS-derived  $\rho(745)$ , and the third (i,j,k,l) to concentrations calculated via the transitional model.

## 611 5. Concluding remarks

612 The increasing concern in monitoring synoptically coastal systems has made passive  
 613 remote sensing one of the most used tools to indirectly estimate the TSM concentration.  
 614 Regarding the social and economic importance of the Patos Lagoon estuarine system, the  
 615 present work illustrates the potential of MODIS/Aqua and VIIRS/NPP sensors for



616 estimating TSM concentrations in the region. As previously said, this is not an easy task,  
617 especially in environments where such an exchange of continental and marine waters  
618 occurs. Due to these export events, the optical components of Patos Lagoon waters are  
619 dominated by CDOM and TSM concentrations, with a low-to-moderate contribution of  
620 CHLa. Each of these constituents influence in different ways the water-leaving reflectance  
621 variability, and at least four spectral groups have been identified during the sampling  
622 period. According to all the statistical analysis presented on Section 4.1., there is a direct  
623 relationship between the suspended particles load and the increase in reflectance intensity,  
624 mainly between 590-700 nm, that also demonstrated to be the most sensitive interval to  
625 TSM variations. For further studies, it is worth to remark that the distinct spectral  
626 signatures in waters of the Patos Lagoon estuarine system are dependent on both TSM and  
627 CDOM concentrations, and the spectral resolution of the current sensors may not be as  
628 efficient at discriminating these differences.

629 *In situ* and satellite-derived spectral reflectance data were compared to evaluate the  
630 best atmospheric correction method. According to the match-ups, the NIR-SWIR-based  
631 corrections produced good results for MODIS products. Whereas, for the VIIRS-derived  $\rho$ ,  
632 both iterative NIR, standard and modified NIR-SWIR algorithms showed good  
633 performances. A general undervaluation of  $\rho$  is observed when these atmospheric models  
634 were applied and could be explained by two potential reasons: (1) an over-correction of  
635 aerosols using the NIR and SWIR methods, which lead to producing lower  $\rho$  values; or (2)  
636 influence of land or cloud reflectances over nearshore pixels, that might also induce the  $\rho$   
637 underestimation. These causes might affect data individually or synchronically. Despite  
638 displaying lower errors and good agreement with *in situ*  $\rho$  in match-up procedures, the  
639 MUMM correction presented a scattered distribution when the pixels of the entire scene  
640 was superposed over the whole range of the *in situ* measurements. This latter atmospheric  
641 model unexpectedly produced higher reflectance values in comparison to other corrections,  
642 mainly when lower  $\rho$  values were analyzed. The inter-comparison between all  
643 atmospherically corrected products also showed very good agreement between iterative  
644 NIR, standard NIR-SWIR and modified NIR-SWIR corrections.

645 Three TSM algorithms were produced from *in situ*  $\rho$ , which were previously  
646 weighted to each sensor relative spectral response. A non-linear relationship was observed  
647 between TSM and  $\rho(\text{red})$ , which tended to saturate when concentrations exceeded 40-  
648 45mg/L. The  $\rho(\text{NIR})$ , on the other hand, presented a greater sensitivity to high TSM  
649 concentrations, showing a linear behavior with the increasing suspended sediment load.  
650 Hence, two polynomial algorithms were created from  $\rho(645)$  and  $\rho(671)$ , whereas a linear  
651 model was developed from the  $\rho(745)$ . In general, all models presented good results,  
652 mainly the polynomial red ones. The linear NIR model presented the highest errors and  
653 more biased results. However, these inaccuracies still fall into an admissible range  
654 according to the literature. After the development of the models, the resulting algorithms  
655 were tested in satellite-derived  $\rho$  and then compared to a new concurrent TSM dataset. In  
656 general, the TSM concentrations estimated from the polynomial red models showed better  
657 agreement when iterative NIR and modified NIR-SWIR products were used, whereas those  
658 estimated from the linear NIR algorithm presented superior results for both standard and  
659 modified NIR-SWIR atmospherically corrected  $\rho$ . The MUMM correction demonstrated  
660 the worst efficacy in predicting TSM concentration for all bands. These results reflected the  
661 same pattern found in previous atmospheric validations.

662 The TSM maps created from the MODIS and VIIRS bands showed great  
663 accordance with each other, as well as with the true color composite images acquired on the  
664 same day. However, during highly turbid conditions the TSM concentrations estimated  
665 from the linear NIR algorithm evinced higher values than those estimated from the  
666 polynomial models. Hence, the methodology proposed by Novoa et al. (2017) was adapted  
667 and applied to the VIIRS data. Here, a transitional algorithm was assembled through the  
668 unification of the models created from  $\rho(671)$  and  $\rho(745)$  based on the determination of a  
669 switching point and a smooth interval for the changeover. Thus, the lower TSM values were  
670 calculated through the polynomial red model while the linear NIR was required when these  
671 concentrations increased. It demonstrated a superior performance when strong gradients  
672 were formed from inner to the outer lagoon, whilst single-band polynomial models  
673 presented some saturation. Besides, low-to-moderately turbid conditions were better

674 represented when the polynomial algorithm was applied, since higher noise interference  
675 was found for the linear NIR model within this TSM range. It is worth to remark that  
676 proper recalibration and validation must be done to assess these model performance, once  
677 the highest value used for regressions was 95 mg/L, and TSM might reach up to hundreds  
678 of mg/L during sporadic events.

679 Overall, the presented algorithms showed good agreement with *in situ*  
680 measurements, especially for NIR bands. Our models could be appropriately used in the  
681 Patos Lagoon estuary through the MODIS/Aqua and VIIRS/NPP data. Despite the coarser  
682 spatial resolution, VIIRS/NPP data presented good atmospheric validations and could have  
683 properly described the TSM dynamics, even roughly recognizing features similar to those  
684 illustrated by the MODIS sensor. Preliminary analysis has shown that VIIRS/JPSS-1 also  
685 demonstrated an appropriate atmospheric validation. Then, these next generation of  
686 sensors, which are designated to provide ocean color data continuity for the science  
687 community, represent potential tools for estimating TSM in the Patos Lagoon estuary.

688 *Authors Contribution:* **L.L. Sartorato:** Conceptualization of this study, Writing - Original  
689 draft preparation, Methodology, Software, Formal analysis, Data curation, Investigation.  
690 **C.A.E. Garcia:** Conceptualization of this study, Writing - review and editing,  
691 Methodology, Methodology Supervision, Project administration, Resources, Funding  
692 acquisition. All authors have read and agreed to the published version of the manuscript.

693 *Declaration of Interest:* none.

694 *Acknowledgments:* The present work was funded by the National Council for Scientific  
695 and Technological Development (CNPq, Grants 88882.182294/2018-01 and 428039/2016-  
696 2). The Institute of Oceanography of the Federal University of Rio Grande is acknowledged  
697 for providing the infrastructure. Dr. Peter Zavalov is thanked for providing TSM data for  
698 the 2017 campaign. Dr. Inia S. Ramos has provided the look-up table for correcting field  
699 measurements of spectral reflectance. NASA is thanked for the MODIS/Aqua and

700 VIIRS/NPP imagery, as well as the SeaDAS software. The Brazilian Coastal Monitoring  
701 System (Sistema de Monitoramento da Costa Brasileira, SiMCosta) is thanked for all the  
702 assistance during the field campaigns. We also thank Rstudio Team and the Python  
703 Software Foundation for providing the necessary tools for the current work development.

## 6. Supplementary Materials




Figure S1. Comparisons between all the atmospherically corrected  $\rho(645)$ -MODIS/Aqua: the standard NIR versus standard NIR-SWIR (a), modified NIR-SWIR (b), and MUMM (c), the standard NIR-SWIR versus modified NIR-SWIR (d), and MUMM (e), and finally, the modified NIR-SWIR versus MUMM (f). Hot to cold colors represent the decreasing gradient of pixel density. Reflectances from all scenes acquired in 2018-2019 were used.

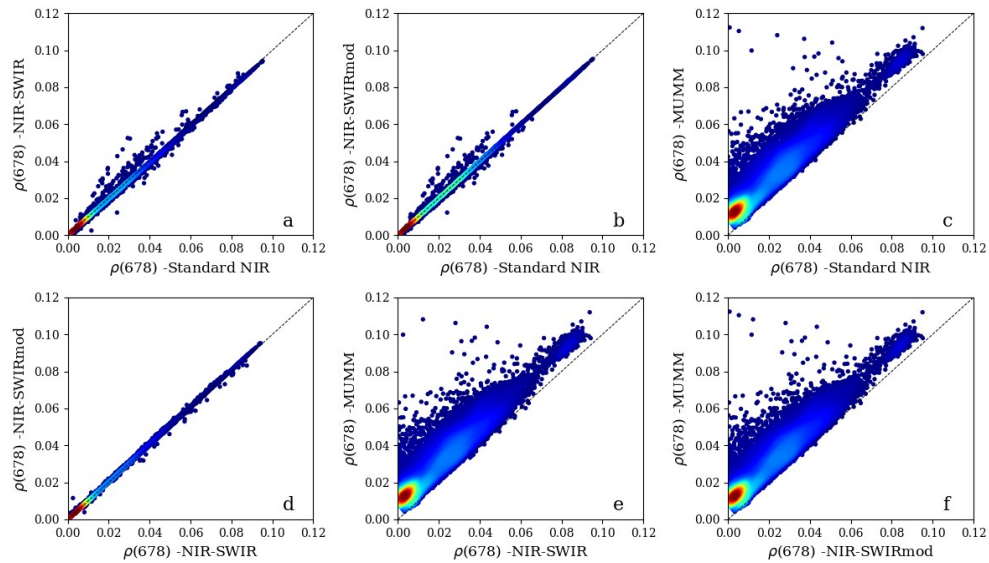


Figure S2 Comparisons between all the atmospherically corrected  $\rho(678)$ -VIIRS/SNPP: the standard NIR versus standard NIR-SWIR (a), modified NIR-SWIR (b), and MUMM (c), the standard NIR-SWIR versus modified NIR-SWIR (d), and MUMM (e), and finally, the modified NIR-SWIR versus MUMM (f). Hot to cold colors represent the decreasing gradient of pixel density. Reflectances from all scenes acquired in 2018-2019 were used.

## **Capítulo VII: Síntese da Discussão e Conclusões**

O crescente interesse global sobre o monitoramento sinóptico de sistemas marinhos costeiros fez com que o sensoriamento remoto passivo se tornasse uma das ferramentas indiretas mais utilizadas para estimar a concentração de TSM nessas regiões. Considerando a importância social e econômica do sistema estuarino da Lagoa dos Patos, bem como a carência de estudos sobre o tema, o presente trabalho ilustra o potencial dos sensores MODIS-Aqua e VIIRS-NPP em estimar a concentração de TSM na área. E como foi dito anteriormente, esta não se traduz como uma tarefa fácil, uma vez em águas complexas não há relação linear direta entre os constituintes opticamente ativos presentes no meio e correções atmosféricas apropriadas devem ser empregadas.

De acordo com a literatura e os dados ilustrados no presente estudo, o ELP se configura como um ambiente muito dinâmico onde o intercâmbio de águas costeiras e continentais é recorrente. Em geral, a salinidade dentro da laguna é menor do que em zonas marinhas adjacentes. Contudo, ambas as regiões demonstraram valores máximos e mínimos de salinidade similares, indicando ocorrências tanto da entrada de águas salgadas no interior do estuário, como da maior descarga continental e consequente avanço da pluma em direção ao oceano. As concentrações de CDOM e TSM, assim como os coeficientes de atenuação tendem a aumentar na região lagunar, e possuem correlação negativa com a salinidade, de maneira geral. Tais resultados reforçam a importância da influência das águas continentais sobre o ambiente costeiro, e vice-versa, de modo que apesar dos dois sistemas possuírem características distintas, se inter-relacionam muito.

Por conta disso, o ELP possui uma complexa composição óptica, onde suas águas são dominadas pelas concentrações de CDOM e TSM, com baixas a moderadas concentrações de CHLa. Cada um destes constituintes influencia a variabilidade da reflectância que retorna da água diferentemente, de forma que quatro classes espectrais foram identificadas durante o período de coleta, sendo que todas apresentaram características típicas de águas complexas do Tipo II. Dentre esses subgrupos, três apresentaram forte codominância entre as concentrações de CDOM e TSM na sua composição óptica e o outro demonstrou relevante contribuição de concentração de CHLa (25%). Os dois primeiros

constituintes são responsáveis pela maior variabilidade das assinaturas espectrais nas águas da ELP, enquanto que a CHLa possui um papel mais secundário sobre essas variações. De acordo com as análises estatísticas apresentadas, existe uma relação direta entre a concentração de materiais particulados suspensos na água e o aumento da intensidade da reflectância, principalmente na faixa entre 590 e 700 nm, demonstrando ser o intervalo mais sensível às variações da concentração de TSM.

Os dados de reflectâncias derivados por satélite e coletados *in situ* foram comparados a fim de avaliar as performances de cada correção atmosférica aplicada. De acordo com as comparações, as correções baseadas no método de troca NIR-SWIR (padrão e adaptada) produziram os valores de reflectância mais realísticos para os produtos do sensor MODIS. Ao passo que para o sensor VIIRS, as reflectâncias extraídas pelas correções padrão NIR e NIR-SWIR, bem como pelo modelo adaptado NIR-SWIR, apresentaram boas correlações com as reflectâncias convolucionadas coletadas *in situ*. Uma tendência geral de subestimar  $\rho$  foi verificada, sobretudo quando a correção iterativa NIR foi aplicada. Isto pode ter ocorrido por duas potenciais razões: (1) uma correção excessiva dos aerossóis, que leva à produção de valores menores de reflectância, ou (2) devido à influência de reflectâncias provenientes da costa e nuvens sobre alguns pixels, que também pode provocar essa subestimativa. Esses efeitos ainda podem afetar individualmente ou mutualmente o processo de aquisição e cálculo das



reflectâncias oriundas da água. A inter-comparação entre os produtos oriundos de dessas correções demonstrou grande concordância entre os mesmos.

Apesar de apresentar os menores erros absolutos e relativos em relação às  $\rho$  *in situ*, os produtos procedentes da correção atmosférica de MUMM também demonstraram o comportamento mais disperso. Ao comparar banda a banda –  $\rho(671)$  e  $\rho(745)$  – muitos pixels ficaram fora do intervalo de 95% de confiança (Figura 6). Esta última correção produziu, inesperadamente, valores mais altos de reflectância em comparação aos três outros modelos, principalmente quando valores mais baixos de  $\rho$  foram analisados.

Posteriormente ao procedimento de validação das correções atmosféricas, os algoritmos de TSM foram criados e calibrados a partir dos dados de  $\rho$  coletados *in situ*, os quais foram previamente ponderados utilizando as respostas espectrais relativas de cada sensor. Uma relação não-linear foi observada entre a concentração de TSM e  $\rho$  nas faixas do vermelho (645 e 671 nm), que demonstraram uma tendência à saturação quando essas concentrações excediam 40-45 mg/L. A reflectância convolucionada na banda NIR (745 nm), por outro lado, apresentou maior sensibilidade ao progressivo aumento de TSM, exibindo um comportamento linear. Assim, modelos polinomiais de segunda ordem foram criados a partir de  $\rho(645)$  e  $\rho(671)$ , enquanto que um de primeira ordem foi desenvolvido a partir de  $\rho(745)$ . Em geral, todos estes algoritmos apresentaram bons coeficientes de correlação e baixos erros, principalmente os polinomiais de segunda ordem das bandas do vermelho. O modelo linear do NIR evidenciou erros

relativamente maiores e resultados mais tendenciosos positivamente. Apesar disso, essas incertezas ainda estão dentro de um intervalo aceitável, de acordo com a literatura.

Após o desenvolvimento desses algoritmos para o cálculo da concentração de TSM, os mesmos foram testados e validados utilizando as  $\rho$  derivadas pelos sensores remotos e então comparados com novos dados coincidentes de concentração de TSM coletados *in situ*. Em geral, para ambos os sensores, as concentrações estimadas pelos modelos polinomiais de segunda ordem apresentaram melhor concordância com os dados *in situ* quando as correções NIR padrão e NIR-SWIR adaptada foram empregadas. Já as concentrações de TSM calculadas a partir do modelo de primeira ordem (linear) NIR demonstraram melhores concordâncias com os dados de validação quando as correções baseadas no algoritmo NIR-SWIR (adaptado e padrão) foram utilizadas. As concentrações de TSM calculadas a partir das reflectâncias extraídas pela correção MUMM demonstraram a pior correspondência com os dados *in situ* para todas as bandas analisadas. De modo geral, as concentrações de TSM que mais se aproximaram dos dados *in situ*, foram aquelas estimadas a partir das reflectâncias extraídas pelas correções atmosféricas com os melhores *match-ups*. Este mesmo processo de validação foi conduzido utilizando o modelo semi-analítico proposto por Nechad et al. (2010) para o cálculo de TSM. De forma genérica, a performance destes algoritmos foi inferior à dos modelos propostos

neste trabalho, principalmente quando as bandas do NIR e a correção atmosférica MUMM foram utilizadas para estimar a concentração de TSM.

Os mapas de concentração de TSM criados a partir das bandas do MODIS e VIIRS apresentaram boa conformidade entre si, bem como com as imagens de “cor verdadeira” adquiridas no mesmo dia. Contudo, durante condições claramente mais túrbidas, as concentrações de TSM estimadas a partir do algoritmo linear NIR evidenciaram valores mais altos do que os estimados nos modelos polinomiais de segunda ordem. Portanto, a metodologia proposta por Novoa et al. (2017), na qual um algoritmo de transição suave entre bandas é criado, foi adaptada e aplicada aos dados do VIIRS. Neste caso, um modelo de transição foi montado através da unificação dos algoritmos polinomiais de segunda e primeira ordem criados a partir de  $\rho(671)$  e  $\rho(745)$  com base na determinação de um ponto de comutação e um intervalo de suavização entre eles. Assim, as menores concentrações de TSM foram estimadas através do modelo polinomial de 2ª ordem da banda do vermelho, enquanto que o modelo linear NIR foi utilizado quando essas concentrações eram mais altas. Esta abordagem demonstrou um desempenho superior em relação aos dois outros modelos utilizados individualmente, principalmente quando fortes gradientes de TSM formaram-se do interior para o exterior da laguna. Durante esses eventos, a saturação causada pelos modelos polinomiais de 2ª ordem de banda única foram evidenciadas. Além disso, baixas a moderadas concentrações de TSM foram melhores estimadas quando o algoritmo polinomial de 2ª ordem foi aplicado, uma

vez que foi encontrada maior interferência de ruídos quando os valores de  $\rho(745)$  eram mais baixos, de modo a afetar negativamente a performance do algoritmo linear quando aplicado nessa condição. Apesar de o ELP apresentar concentrações moderadas de TSM na maior parte do tempo, é válido ressaltar que posteriores recalibração e validação devem ser feitas para avaliar o desempenho do modelo, uma vez que o valor mais alto usado para regressões foi de 95 mg/L, e as concentrações TSM pode atingir centenas de mg/L durante eventos esporádicos.

No geral, as concentrações de TSM estimadas pelos algoritmos aqui propostos demonstraram boa concordância com os dados *in situ*, especialmente para bandas do NIR, de modo que esses modelos podem ser utilizados adequadamente no estuário da Lagoa de Patos através dos dados de reflectância do MODIS-Aqua e VIIRS-NPP. Apesar da resolução espacial mais grosseira, os dados do VIIRS apresentaram boas validações atmosféricas e descreveram adequadamente a dinâmica do TSM, reconhecendo características e feições semelhantes às ilustradas pelo sensor MODIS. Com o presente trabalho foi possível averiguar que esta nova geração de sensores, inicialmente designada para dar continuidade dos dados de cor do oceano para a comunidade científica, representa uma potencial ferramenta para estimar a concentração de TSM no estuário da Lagoa de Patos. Recomenda-se a trabalhos futuros o uso de outros sensores disponíveis, como o OLCI abordo do satélite Sentinel-3 ou o VIIRS abordo do satélite JPSS-1, que também

demonstrou bons resultados de validação atmosférica em algumas análises preliminares.

## Referências Bibliográficas

- Acker, J. G., Ouillon, S., Gould, Richard W., J., & Arnone, R. A. (2005). Measuring Marine Suspended Sediment Concentrations from Space: History and Potential. *International Conference on Remote Sensing for Marine and Coastal Environments, February 2005*.
- Acker, J., Ouillon, S., Gould, R., & Arnone, R. (2005). Measuring Marine Suspended Sediment Concentrations from Space: History and Potential. *International Conference on Remote Sensing for Marine and Coastal Environments*, 10. [http://www.mio.univ-amu.fr/~petrenko/TEACHING/OPCB343/Acker\\_et\\_al\\_Proc2005\\_SPM\\_from\\_satellite.pdf](http://www.mio.univ-amu.fr/~petrenko/TEACHING/OPCB343/Acker_et_al_Proc2005_SPM_from_satellite.pdf)
- Allison, D. B., Stramski, D., & Mitchell, B. G. (2010). Empirical ocean color algorithms for estimating particulate organic carbon in the Southern Ocean. *Journal of Geophysical Research: Oceans*, 115(10), 1–16. <https://doi.org/10.1029/2009JC006040>
- Antiqueira, J., & Calliari, L. (2005). Características sedimentares da desembocadura da Laguna dos Patos. *Gravel*, 3, 39–46. <http://www.scopus.com/inward/record.url?eid=2-s2.0-77954798972&partnerID=40&md5=26415e07658ecbbac043d3093f4c9103%5Cnhttp://repositorio.furg.br:8080/jspui/handle/1/2141>
- Aurin, D., Mannino, A., & Franz, B. (2013). Spatially resolving ocean color and sediment dispersion in river plumes, coastal systems, and continental shelf waters. *Remote Sensing of Environment*, 137, 212–225. <https://doi.org/10.1016/j.rse.2013.06.018>
- Bailey, S. W., Franz, B. A., & Werdell, P. J. (2010). Estimation of near-infrared water-leaving reflectance for satellite ocean color data processing. *Optics Express*, 18(7), 7521. <https://doi.org/10.1364/oe.18.007521>
- Bailey, S., & Wang, M. (2001). Satellite Aerosol Optical Thickness Match-Up Procedures. In *In Situ Aerosol Optical Thickness Collected by the SIMBIOS Program (1997-2000): Protocols, and Data QC and Analysis* (Issue April, pp. 70–72).

- Bilotta, G. S., & Brazier, R. E. (2008). Understanding the influence of suspended solids on water quality and aquatic biota. *Water Research*, 42(12), 2849–2861. <https://doi.org/10.1016/j.watres.2008.03.018>
- Binding, C. E., Bowers, D. G., & Mitchelson-Jacob, E. G. (2005). Estimating suspended sediment concentrations from ocean colour measurements in moderately turbid waters; The impact of variable particle scattering properties. *Remote Sensing of Environment*, 94(3), 373–383. <https://doi.org/10.1016/j.rse.2004.11.002>
- Bowers, D. G., & Binding, C. E. (2006). The optical properties of mineral suspended particles: A review and synthesis. *Estuarine, Coastal and Shelf Science*, 67(1–2), 219–230. <https://doi.org/10.1016/j.ecss.2005.11.010>
- Bricaud, A., Claustre, H., Ras, J., & Oubelkheir, K. (2004). Natural variability of phytoplanktonic absorption in oceanic waters: Influence of the size structure of algal populations. *Journal of Geophysical Research: Oceans*, 109(11), 1–12. <https://doi.org/10.1029/2004JC002419>
- Cai, W.-J. (2011). Estuarine and Coastal Ocean Carbon Paradox: CO<sub>2</sub> Sinks or Sites of Terrestrial Carbon Incineration? . *Annual Review of Marine Science*, 3(1), 123–145. <https://doi.org/10.1146/annurev-marine-120709-142723>
- Calliari, L. J., Winterwerp, J. C., Fernandes, E., Cuchiara, D., Vinzon, S. B., Sperle, M., & Holland, K. T. (2009). Fine grain sediment transport and deposition in the Patos Lagoon-Cassino beach sedimentary system. *Continental Shelf Research*, 29(3), 515–529. <https://doi.org/10.1016/j.csr.2008.09.019>
- Cao, C., Xiong, J., Blonski, S., Liu, Q., Uprety, S., Shao, X., Bai, Y., & Weng, F. (2013). Suomi NPP VIIRS sensor data record verification, validation, and long-term performance monitoring. *Journal of Geophysical Research Atmospheres*, 118(20), 11664–11678. <https://doi.org/10.1002/2013JD020418>
- Cao, Z., Duan, H., Shen, M., Ma, R., Xue, K., Liu, D., & Xiao, Q. (2018). Using VIIRS/NPP and MODIS/Aqua data to provide a continuous record of suspended particulate matter in a highly turbid inland lake. *International Journal of Applied Earth Observation and Geoinformation*, 64(October 2017), 256–265. <https://doi.org/10.1016/j.jag.2017.09.012>
- Castelao, R. M., & Moller Jr, O. O. (2006). A modeling study of Patos lagoon (Brazil) flow response to idealized wind and river discharge: dynamical

- analysis. *Brazilian Journal of Oceanography*, 54(1), 1–17. <https://doi.org/10.1590/s1679-87592006000100001>
- Chaichitehrani, N., Hestir, E. L., & Li, C. (2018). Evaluation of Atmospheric Correction Algorithms for Landsat-8 OLI and MODIS-Aqua to Study Sediment Dynamics in the Northern Gulf of Mexico. *Advances in Remote Sensing*, 07(02), 101–124. <https://doi.org/10.4236/ars.2018.72008>
- Chen, Z., Hu, C., & Muller-Karger, F. (2007). Monitoring turbidity in Tampa Bay using MODIS/Aqua 250-m imagery. *Remote Sensing of Environment*, 109(2), 207–220. <https://doi.org/10.1016/j.rse.2006.12.019>
- CONAMA. (2012). *Current Conama Resolutions published between September 1984 and January 2012*. 1126. <http://www.mma.gov.br/port/conama/processos/61AA3835/CONAMA-ingles.pdf>
- Costi, J., Moraes, B. C., & Marques, W. C. (2017). A regional algorithm for investigating the Patos Lagoon coastal plume using Aqua/MODIS and oceanographic data. *Marine Systems & Ocean Technology*, 12(3), 166–177. <https://doi.org/10.1007/s40868-017-0032-4>
- de Andrade Neto, J. S., Rigon, L. T., Toldo, E. E., & Schettini, C. A. F. (2012). Descarga sólida em suspensão do sistema fluvial do Guaíba, RS, e sua variabilidade temporal. *Pesquisas Em Geociencias*, 39(2), 161–171. <https://doi.org/10.22456/1807-9806.35910>
- Di Polito, C., Ciancia, E., Coviello, I., Doxaran, D., Lacava, T., Pergola, N., Satriano, V., & Tramutoli, V. (2016). On the potential of robust satellite techniques approach for SPM monitoring in coastalwaters: Implementation and application over the basilicata ionian coastal waters using MODIS-Aqua. *Remote Sensing*, 8(11). <https://doi.org/10.3390/rs8110922>
- Doxaran, D., Cherukuru, N., & Lavender, S. J. (2004). Apparent and Inherent Optical Properties of Turbid Estuarine Waters: Measurements, Modelling and Application to Remote Sensing. *Estuaries*, 2001(figure 1), 1–14.
- Doxaran, D., Froidefond, J.-M., Lavender, S., & Castaing, P. (2002). Spectral signature of highly turbid waters. *Remote Sensing of Environment*, 81(1), 149–161. [https://doi.org/10.1016/s0034-4257\(01\)00341-8](https://doi.org/10.1016/s0034-4257(01)00341-8)
- Doxaran, D., Leymarie, E., Nechad, B., Dogliotti, A., Ruddick, K., Gernez, P., & Knaeps, E. (2016). Improved correction methods for field measurements of



- particulate light backscattering in turbid waters. *Optics Express*, 24(4), 3615. <https://doi.org/10.1364/OE.24.003615>
- Fassoni-Andrade, A. C., & Paiva, R. C. D. de. (2019). Mapping spatial-temporal sediment dynamics of river-floodplains in the Amazon. *Remote Sensing of Environment*, 221(October 2018), 94–107. <https://doi.org/10.1016/j.rse.2018.10.038>
- Garcia, C. A. E., Garcia, V. M. T., & McClain, C. R. (2005). Evaluation of SeaWiFS chlorophyll algorithms in the Southwestern Atlantic and Southern Oceans. *Remote Sensing of Environment*, 95(1), 125–137. <https://doi.org/10.1016/j.rse.2004.12.006>
- Gordon, H. R., & Morel, A. Y. (1983). *Remote Assessment of Ocean Color for Interpretation of Satellite Visible Imagery: A Review* (M. J. B. and B. Z. R. T. Barber, N. K. Mooers (ed.)). Springer-Verlag.
- Gould, R. W., Arnone, R. A., & Martinolich, P. M. (1999). Spectral dependence of the scattering coefficient in case 1 and case 2 waters. *Applied Optics*, 38(12), 2377. <https://doi.org/10.1364/AO.38.002377>
- Goyens, C., Jamet, C., & Ruddick, K. G. (2013). Spectral relationships for atmospheric correction II Improving NASA's standard and MUMM near infrared modeling schemes. *Optics Express*, 21(18), 21176. <https://doi.org/10.1364/OE.21.021176>
- Goyens, C., Jamet, C., & Schroeder, T. (2013). Evaluation of four atmospheric correction algorithms for MODIS-Aqua images over contrasted coastal waters. *Remote Sensing of Environment*, 131(April), 63–75. <https://doi.org/10.1016/j.rse.2012.12.006>
- Han, B., Loisel, H., Vantrepotte, V., Mériaux, X., Bryère, P., Ouillon, S., Dessailly, D., Xing, Q., & Zhu, J. (2016). Development of a semi-analytical algorithm for the retrieval of suspended particulate matter from remote sensing over clear to very turbid waters. *Remote Sensing*, 8(3). <https://doi.org/10.3390/rs8030211>
- Hartmann, C., & Schettini, C. A. F. (1991). Aspectos Hidrológicos Na Desembocadura Da Laguna Dos Patos, Rs. *Revista Brasileira de Geociências*, 21(4), 371–377. <https://doi.org/10.25249/0375-7536.1991371377>
- Hlaing, S., Harmel, T., Gilerson, A., Foster, R., Weidemann, A., Arnone, R., Wang, M., & Ahmed, S. (2013). Evaluation of the VIIRS ocean color monitoring

- performance in coastal regions. *Remote Sensing of Environment*, 139, 398–414. <https://doi.org/10.1016/j.rse.2013.08.013>
- Howarth, W. (2008). The marine strategy framework directive. *Journal of Water Law*, 19(3), 95–97.
- Hu, C., Chen, Z., Clayton, T. D., Swarzenski, P., Brock, J. C., & Muller-Karger, F. E. (2004). Assessment of estuarine water-quality indicators using MODIS medium-resolution bands: Initial results from Tampa Bay, FL. *Remote Sensing of Environment*, 93(3), 423–441. <https://doi.org/10.1016/j.rse.2004.08.007>
- Hu, C., & Le, C. (2014). Ocean color continuity from VIIRS measurements over tampa bay. *IEEE Geoscience and Remote Sensing Letters*, 11(5), 945–949. <https://doi.org/10.1109/LGRS.2013.2282599>
- Ioannou, I., Gilerson, A., Gross, B., Moshary, F., & Ahmed, S. (2011). Neural network approach to retrieve the inherent optical properties of the ocean from observations of MODIS. *Applied Optics*, 50(19), 3168. <https://doi.org/10.1364/ao.50.003168>
- IOCCG. (2000). 03. Remote Sensing of Ocean Colour in Coastal, and Other Optically-Complex, Waters. In *IOCCG web page* (Vol. 3). <http://www.vliz.be/imis/imis.php?module=ref&refid=134621&request=147862>
- IOCCG. (2007). 06. Ocean-colour data merging. In *IOCCG web page*. <http://www.ioccg.org/reports/report6.pdf>
- IOCCG. (2008). 07. Why ocean colour? The societal benefits of ocean-colour technology. In *IOCCG web page* (Issue 7). <http://www.ioccg.org/reports/report7.pdf>
- IOCCG. (2010). 10. Atmospheric correction for remotely-sensed ocean-colour products. In *IOCCG web page* (Issue 10). <http://www.ioccg.org/reports/report10.pdf>
- Jackson, J. M., Liu, H., Laszlo, I., Kondragunta, S., Remer, L. A., Huang, J., & Huang, H. C. (2013). Suomi-NPP VIIRS aerosol algorithms and data products. *Journal of Geophysical Research Atmospheres*, 118(22), 12,673–12,689. <https://doi.org/10.1002/2013JD020449>

- Jamet, C., Loisel, H., Kuchinke, C. P., Ruddick, K., Zibordi, G., & Feng, H. (2011). Comparison of three SeaWiFS atmospheric correction algorithms for turbid waters using AERONET-OC measurements. *Remote Sensing of Environment*, 115(8), 1955–1965. <https://doi.org/10.1016/j.rse.2011.03.018>
- Kirk, J. T. O. (1984). Dependence of relationship between inherent and apparent optical properties of water on solar altitude. *Limnology and Oceanography*, 29(2), 350–356. [file:///D:/DKP/Papers/LO/Vol29\\_No2\\_0350.pdf](file:///D:/DKP/Papers/LO/Vol29_No2_0350.pdf)
- Kitchen, J. C., Zaneveldan, J. R. V., & Pak, H. (1982). Effect of particle size distribution and chlorophyll content on beam attenuation spectra. *Applied Optics*, 21(21), 3913. <https://doi.org/10.1364/ao.21.003913>
- Kjerfve, B. (1986). Comparative Oceanography of Coastal Lagoons. *Estuarine Variability*, 63–81. <https://doi.org/10.1016/b978-0-12-761890-6.50009-5>
- Knaeps, E., Dogliotti, A. I., Raymaekers, D., Ruddick, K., & Sterckx, S. (2012). In situ evidence of non-zero reflectance in the OLCI 1020nm band for a turbid estuary. *Remote Sensing of Environment*, 120, 133–144. <https://doi.org/10.1016/j.rse.2011.07.025>
- Knaeps, E., Ruddick, K. G., Doxaran, D., Dogliotti, A. I., Nechad, B., Raymaekers, D., & Sterckx, S. (2015). A SWIR based algorithm to retrieve total suspended matter in extremely turbid waters. *Remote Sensing of Environment*, 168, 66–79. <https://doi.org/10.1016/j.rse.2015.06.022>
- Larouche, P., & Canada, O. (2003). *Spectroradiométrie De La Matière Particulaire Dans L ' Oued Sebou ( Maroc ) : Application Aux Données De Télédétection Spectroradiometry of Particulate Matter in the Oued Sebou ( Morocco ) : Application To*. 3(August 2003), 85–96.
- Li, R., Kaufman, Y. J., Gao, B., & Davis, C. O. (2003). Remote Sensing of Suspended Sediments and Shallow Coastal Waters. *IEEE Transactions on Geoscience and Remote Sensing*, 41(3), 559–566. <https://doi.org/10.1109/TGRS.2003.810227>
- Marques, W. C., Fernandes, E. H. L., Moraes, B. C., Möller, O. O., & Malcherek, A. (2010). Dynamics of the Patos Lagoon coastal plume and its contribution to the deposition pattern of the southern Brazilian inner shelf. *Journal of Geophysical Research: Oceans*, 115(10), 1–22. <https://doi.org/10.1029/2010JC006190>

- Medeiros, P. M., Bicego, M. C., Castelao, R. M., Del Rosso, C., Fillmann, G., & Zamboni, A. J. (2005). Natural and anthropogenic hydrocarbon inputs to sediments of Patos Lagoon Estuary, Brazil. *Environment International*, 31(1), 77–87. <https://doi.org/10.1016/j.envint.2004.07.001>
- Mobley, C. D. (1994). *Light and Water: Radiative transfer in the natural waters*. In Academic Press.
- Mobley, C. D. (1999). Estimation of the remote-sensing reflectance from above-surface measurements. *Applied Optics*, 38(36), 7442. <https://doi.org/10.1364/AO.38.007442>
- Möller, O. O., & Castaing, P. (1999). Hydrographical Characteristics of the Estuarine Area of Patos Lagoon (30°S, Brazil). *Estuaries of South America*, 83–100. [https://doi.org/10.1007/978-3-642-60131-6\\_5](https://doi.org/10.1007/978-3-642-60131-6_5)
- Möller, O. O., Castaing, P., Salomon, J. C., & Lazure, P. (2001). The influence of local and non-local forcing effects on the subtidal circulation of Patos Lagoon. *Estuaries*, 24(2), 297–311. <https://doi.org/10.2307/1352953>
- Möller, O. O., Lorenzenti, J. A., Stech, J. L., & Mata, M. M. (1996). The Patos Lagoon summertime circulation and dynamics. *Continental Shelf Research*, 16(3), 335–351. [https://doi.org/10.1016/0278-4343\(95\)00014-R](https://doi.org/10.1016/0278-4343(95)00014-R)
- Mueller, J. L., Davis, C., Arnone, R., Frouin, R., Carder, K., Lee, Z. P., Steward, R. G., Hooke, S., Mobley, C. D., & McLean, S. (2000). *Ocean Optics Protocols For Satellite Ocean Color Sensor Validation Chapter - Chapter 10. Above-Water Radiance and Remote Sensing Reflectance Measurement and Analysis Protocols* (Issue November 2016).
- Nechad, B., Ruddick, K. G., & Park, Y. (2010a). Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters. *Remote Sensing of Environment*, 114(4), 854–866. <https://doi.org/10.1016/j.rse.2009.11.022>
- Nechad, B., Ruddick, K. G., & Park, Y. (2010b). Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters. *Remote Sensing of Environment*, 114(4), 854–866. <https://doi.org/10.1016/j.rse.2009.11.022>
- Newcombe, C. P., & MacDonald, D. (1991). North American Journal of Effects of Suspended Sediments on Aquatic Ecosystems. *North American Journal of*

*Fisheries Management*, March 2014, 72–82. [https://doi.org/10.1577/1548-8675\(1991\)011<0072](https://doi.org/10.1577/1548-8675(1991)011<0072)

Niencheski, L. F., & Baumgarten, M. G. Z. (2000). Distribution of particulate trace metal in the southern part of the Patos lagoon estuary. *Aquatic Ecosystem Health and Management*, 3(4), 515–520. <https://doi.org/10.1080/14634980008650688>

Niencheski, L. F., & Windom, H. L. (1994). Nutrient flux and budget in Patos Lagoon estuary. *Science of the Total Environment*, 149(1–2), 53–60. [http://search.proquest.com/docview/16956389?accountid=27991%5Cnhttp://link.periodicos.capes.gov.br/sfxlcl41?url\\_ver=Z39.88-2004&rft\\_val\\_fmt=info:ofi/fmt:kev:mtx:journal&genre=article&sid=ProQ:ProQ%3Aasfabiological&atitle=Nutrient+flux+and+budget+in+Patos+](http://search.proquest.com/docview/16956389?accountid=27991%5Cnhttp://link.periodicos.capes.gov.br/sfxlcl41?url_ver=Z39.88-2004&rft_val_fmt=info:ofi/fmt:kev:mtx:journal&genre=article&sid=ProQ:ProQ%3Aasfabiological&atitle=Nutrient+flux+and+budget+in+Patos+)

Novo, E. M. L. de M., Barbosa, C. C. de F., Freitas, R. M., Shimabukuro, Y. E., Melack, J. M., & Filho, W. P. (2006). Seasonal changes in chlorophyll distributions in Amazon floodplain lakes derived from MODIS images. *Limnology*, 7(3), 153–161. <https://doi.org/10.1007/s10201-006-0179-8>

Novoa, S., Doxaran, D., Ody, A., Vanhellemont, Q., Lafon, V., Lubac, B., & Gernez, P. (2017). Atmospheric corrections and multi-conditional algorithm for multi-sensor remote sensing of suspended particulate matter in low-to-high turbidity levels coastal waters. *Remote Sensing*, 9(1). <https://doi.org/10.3390/rs9010061>

Ody, A., Doxaran, D., Vanhellemont, Q., Nechad, B., Novoa, S., Many, G., Bourrin, F., Verney, R., Pairaud, I., & Gentili, B. (2016). Potential of high spatial and temporal ocean color satellite data to study the dynamics of suspended particles in a micro-tidal river plume. *Remote Sensing*, 8(3). <https://doi.org/10.3390/rs8030245>

Pagot, M., Rodríguez, A., Hillman, G., Corral, M., Oroná, C., & Niencheski, L. F. (2007). Remote Sensing Assessment of Suspended Matter and Dynamics in Patos Lagoon. *Journal of Coastal Research*, 10047(10047), 116–129. <https://doi.org/10.2112/1551-5036-47.sp1.116>

Petus, C., Chust, G., Gohin, F., Doxaran, D., Froidefond, J. M., & Sagarminaga, Y. (2010). Estimating turbidity and total suspended matter in the Adour River

- plume (South Bay of Biscay) using MODIS 250-m imagery. *Continental Shelf Research*, 30(5), 379–392. <https://doi.org/10.1016/j.csr.2009.12.007>
- Preisendorfer, R. W. (1976). *Hydrologic Optics Volume I. Introduction*. US Department of Commerce, National Oceanic and Atmospheric Administration.
- Rodrigues, J. P. (2014). *Caracterização bio-óptica das águas do estuário da Lagoa dos Patos, RS - Brazil*. Universidade Federal do Rio Grande.
- Ruddick, K. G., Ovidio, F., & Rijkeboer, M. (2000a). Atmospheric correction of SeaWiFS imagery for turbid coastal and inland waters: comment. *Applied Optics*, 39(6), 893–912. <https://doi.org/10.1364/AO.42.000893>
- Ruddick, K. G., Ovidio, F., & Rijkeboer, M. (2000b). Atmospheric correction of SeaWiFS imagery for turbid coastal and inland waters. *Applied Optics*, 39(6), 893–912. <https://doi.org/10.1364/AO.42.000893>
- Rudorff, N., Rudorff, C. M., Kempel, M., & Ortiz, G. (2018). Remote sensing monitoring of the impact of a major mining wastewater disaster on the turbidity of the Doce River plume off the eastern Brazilian coast. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145(January), 349–361. <https://doi.org/10.1016/j.isprsjprs.2018.02.013>
- Shi, W., & Wang, M. (2007). Detection of turbid waters and absorbing aerosols for the MODIS ocean color data processing. *Remote Sensing of Environment*, 110(2), 149–161. <https://doi.org/10.1016/j.rse.2007.02.013>
- Siegel, D. A., Wang, M., Maritorena, S., & Robinson, W. (2000). Atmospheric correction of satellite ocean color imagery: the black pixel assumption. *Applied Optics*, 39(21), 3582. <https://doi.org/10.1364/AO.39.003582>
- Siswanto, E., Tang, J., Yamaguchi, H., Ahn, Y. H., Ishizaka, J., Yoo, S., Kim, S. W., Kiyomoto, Y., Yamada, K., Chiang, C., & Kawamura, H. (2011). Empirical ocean-color algorithms to retrieve chlorophyll-a, total suspended matter, and colored dissolved organic matter absorption coefficient in the Yellow and East China Seas. *Journal of Oceanography*, 67(5), 627–650. <https://doi.org/10.1007/s10872-011-0062-z>
- Slonecker, E. T., Jones, D. K., & Pellerin, B. A. (2016). The new Landsat 8 potential for remote sensing of colored dissolved organic matter (CDOM). *Marine Pollution Bulletin*, 107(2), 518–527. <https://doi.org/10.1016/j.marpolbul.2016.02.076>

- Small, C., & Nicholls, R. J. (2003). A global analysis of human settlement in coastal zones. *Journal of Coastal Research*, 19(3), 584–599.
- Stramski, D., Boss, E., Bogucki, D., & Voss, K. J. (2004). The role of seawater constituents in light backscattering in the ocean. *Progress in Oceanography*, 61(1), 27–56. <https://doi.org/10.1016/j.pocean.2004.07.001>
- Strickland, J. D. H., & Parsons, T. R. (1972). A Practical Handbook of Seawater Analysis. In J. C. Stevenson, J. Watson, J. M. Reinhart, D. G. Cook, J. Camp, & M. I. Smith (Eds.), *A Practical Handbook of Seawater Analysis* (2nd ed., Vol. 167). Fisheries research board of Canada. [https://doi.org/10.1007/978-1-4615-5439-4\\_19](https://doi.org/10.1007/978-1-4615-5439-4_19)
- Tavora, J., Fernandes, E. H. L., Thomas, A. C., Weatherbee, R., & Schettini, C. A. F. (2019). The influence of river discharge and wind on Patos Lagoon, Brazil, Suspended Particulate Matter. *International Journal of Remote Sensing*, 00(00), 1–20. <https://doi.org/10.1080/01431161.2019.1569279>
- Van Der Woerd, H., & Pasterkamp, R. (2004). Mapping of the North Sea turbid coastal waters using SeaWiFS data. *Canadian Journal of Remote Sensing*, 30(1), 44–53. <https://doi.org/10.5589/m03-051>
- Vanhellemont, Q., & Ruddick, K. (2015). Advantages of high quality SWIR bands for ocean colour processing: Examples from Landsat-8. *Remote Sensing of Environment*, 161, 89–106. <https://doi.org/10.1016/j.rse.2015.02.007>
- Vantrepotte, V., Loisel, H., Dessailly, D., & Mériaux, X. (2012). Optical classification of contrasted coastal waters. *Remote Sensing of Environment*, 123, 306–323. <https://doi.org/10.1016/j.rse.2012.03.004>
- Villar, R. E., Martinez, J. M., Le Texier, M., Guyot, J. L., Fraizy, P., Meneses, P. R., & Oliveira, E. de. (2012). A study of sediment transport in the Madeira River, Brazil, using MODIS remote-sensing images. *Journal of South American Earth Sciences*, 44(July), 1–10. <https://doi.org/10.1016/j.jsames.2012.11.006>
- Vital, H. (2015). *Application of remote sensing for monitoring and evaluation of coastal morphodynamic on the northeastern coast of Brazil*. October, 1–4.
- Wang, M., & Shi, W. (2007). The NIR-SWIR combined atmospheric correction approach for MODIS ocean color data processing Menghua. *Optics Express*, 15(4), 15722–15733. <https://doi.org/10.1029/2004JD004950>

- Whitlock, C. H., Poole, L. R., Usry, J. W., Houghton, W. M., Witte, W. G., Morris, W. D., & Gurganus, E. A. (1981). Comparison of reflectance with backscatter and absorption parameters for turbid waters. *Applied Optics*, 20(3), 517. <https://doi.org/10.1364/ao.20.000517>
- Williamson, R. B., Van Dam, L. F., Bell, R. G., Green, M. O., & Kim, J. P. (1996). Heavy metal and suspended sediment fluxes from a contaminated intertidal inlet (Manukau Harbour, New Zealand). *Marine Pollution Bulletin*, 32(11), 812–822. [https://doi.org/10.1016/S0025-326X\(96\)00044-6](https://doi.org/10.1016/S0025-326X(96)00044-6)
- Zhang, M., Tang, J., Dong, Q., Song, Q. T., & Ding, J. (2010). Retrieval of total suspended matter concentration in the Yellow and East China Seas from MODIS imagery. *Remote Sensing of Environment*, 114(2), 392–403. <https://doi.org/10.1016/j.rse.2009.09.016>