



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS GRADUAÇÃO EM GEOLOGIA E GEOQUÍMICA**

DISSERTAÇÃO DE MESTRADO N° 582

**DUAS DÉCADAS DE MUDANÇAS DOS MANGUEZAIS DE
MESO E MICROMARÉS DO LITORAL BRASILEIRO A
PARTIR DE IMAGENS MULTISENORES**

Dissertação apresentada por:

JOÃO PAULO NOBRE LOPES

Orientador: Prof. Dr. Pedro Walfir Martins e S. Filho (UFPA)

BELÉM – PA

2020

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

L864d Lopes, João Paulo Nobre

Duas décadas de mudanças dos manguezais de meso e micromarés do litoral brasileiro a partir de imagens multisensores / João Paulo Nobre Lopes. — 2020.

xii, 32 f. : il. color.

Orientador(a): Prof. Dr. Pedro Walfir Martins e Souza Filho
Dissertação (Mestrado) - Programa de Pós-Graduação em Geologia e Geoquímica, Instituto de Geociências, Universidade Federal do Pará, Belém, 2020.

1. Sensoriamento remoto. 2. Manguezais. 3. GEOBIA. 4. Detecção de mudanças. I. Título.

CDD 621.3678



Universidade Federal do Pará
Instituto de Geociências
Programa de Pós-Graduação em Geologia e Geoquímica


**DUAS DÉCADAS DE MUDANÇAS DOS MANGUEZAIS DE
MESO E MICROMARÉS DO LITORAL BRASILEIRO A PARTIR
DE IMAGENS MULTISENSORES**


Dissertação apresentada por:
JOÃO PAULO NOBRE LOPES


**Como requisito para à obtenção do Grau de Mestre em Ciências na Área de GEOLOGIA
e Linha de Pesquisa em GEOLOGIA MARINHA E COSTEIRA**

Data da Aprovação: 25 / 05 / 2020

Banca Examinadora:


Prof. Pedro Walfir Martins e S. Filho
(Orientador – UFPA)


Prof. Arnaldo de Queiroz da Silva
(Membro- UFPA)


Wilson da Rocha Nascimento Junior
(Membro – UFPA)

Dedico este trabalho aos meus pais, irmãos, minha família, namorada, amigos e todos que contribuíram direta ou indiretamente para que eu chegasse até aqui.

AGRADECIMENTOS

Nesse momento gostaria de agradecer aquelas pessoas que contribuíram para que eu me tornasse a pessoa que sou hoje e que ajudaram no desenvolvimento deste trabalho.

Primeiramente agradeço a Deus por iluminar os meus passos, me protegendo diariamente e me dando forças para ir em busca dos meus objetivos.

Agradeço aos meus pais Paulo Augusto e Ana Maura por todo o apoio, incentivo e investimento em minha educação. Aos meus irmãos Luiz Paulo, Ana Paula e Paulo Víctor e ao cunhado Carlos Lima por todos os momentos de descontração. Agradeço muito a Deus por ter vocês ao meu lado.

Agradeço a toda minha família, Avós (Luzialva e Maria Raimunda), avô (Raimundo Carlos), tias, tios e primos e primas por todo auxílio durante esse trabalho.

Ao professor Pedro Walfir pelo qual tenho muita admiração pelo exemplo de profissional e atleta. Agradeço por ter aceitado a minha orientação desde projetos de iniciação científica.

Aos amigos do LAIT (Laboratório de Análise de Imagens do Trópico Úmido) Gustavo Miranda, Carlos Reis, Diogo Santos e Paulo Alves. Muito obrigado pela parceria e pelo excelente ambiente de trabalho.

A minha namorada Micaele Castro por todo companheirismo, dicas e parcerias durante o mestrado.

Aos amigos da época de graduação Acácio Pina, Izabelle Serrão e Gabriel Salomão. Amigos de pós-graduação: Isabele Barros, Bettina Bozi, Sérgio Nunes, Renan Fernandes, Nayan César, Luís Felipe.

A biblioteca do Instituto de Geociências, na pessoa de Lúcia Imbiriba, pela paciência e fundamental trabalho nas adequações desta dissertação.

A Universidade Federal do Pará (UFPA) do qual tenho muito orgulho de fazer parte dessa história e por assegurar uma educação de qualidade.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsas ao longo de minha trajetória na pós-graduação.

Por fim gostaria de agradecer a todos que contribuíram de alguma forma no desenvolvimento desta pesquisa.

“Anything is possible”

(IronMan)

*“Nada em mim foi covarde, nem mesmo as
desistências: desistir, ainda que não pareça, foi
meu grande gesto de coragem”*

(Caio Fernando Abreu)

RESUMO

Os manguezais são ambientes costeiros que se estendem ao longo da faixa tropical e subtropical do globo. Seu monitoramento é dificultado por sua ampla distribuição ao longo do litoral brasileiro. Com o advento de novas tecnologias computacionais apoiadas no sensoriamento remoto (Google Earth Engine – GEE), esta problemática foi parcialmente resolvida. Porém, algumas limitações ainda perduram, por exemplo, a utilização de biblioteca de imagens somente de sensores ópticos, dificultando o mapeamento de florestas de mangue em áreas frequentemente cobertas por nuvens. Este trabalho tem o objetivo de avaliar a classificação e as mudanças nas áreas de mangues das regiões de meso e micromaré da zona costeira do Brasil nas últimas duas décadas através de dados multisensores (dados ópticos e de micro-ondas) a partir da utilização da análise de imagens baseada em objetos geográficos (GEOBIA). Foram utilizadas cenas multitemporais da série Landsat, Alos PalSar, JERS SAR e Modelo Digital de Elevação da missão SRTM. O conjunto de imagens foi processada segundo a abordagem de GEOBIA, que determina a redução de uma imagem em regiões homogêneas (objetos) através do agrupamento de conjuntos de pixels com características similares. Como resultados observou-se que em 1996 e 2016 a área em estudo continha 2625,38 km² e 2898,26 km² de áreas de manguezais, respectivamente. Isso demonstra um aumento líquido de 273 km² de áreas de mangues. A partir da análise da detecção de mudanças constatou-se que houve um acréscimo total de 684,55 km², uma perda total de 411,7 km² e permaneceu inalterada uma área de 2213,70 km² de manguezal. A validação da classificação ocorreu através de análises estatísticas de duas matrizes de confusão (1996 e 2016). A matriz de confusão para o ano de 1996 apresentou índices de exatidão global = 0,92; índice Kappa = 0,84; e índice Tau = 0,84. Para o ano de 2016 apresentaram índices de exatidão Global = 0,93; índice Kappa = 0,85; e índice Tau = 0,85. Já a matriz de confusão para a detecção de mudanças mostrou exatidão global de 78,43%, com desacordo por quantidade de 11,86% e desacordo de alocação de 9,71%. As quantificações de perda de manguezal são de 414 ± 43 km², os ganhos são de 590 ± 48 km² e 2305 ± 60,3 km² permaneceram inalteradas. Esses resultados demonstram a eficácia da utilização da classificação orientada a objetos para o mapeamento e análise da dinâmica dos manguezais em escala regional. Os produtos obtidos nesta pesquisa podem servir de base para trabalhos futuros acerca da dinâmica dos manguezais, contribuindo assim para o melhoramento da gestão e preservação desse importante ecossistema.

Palavras-chave: Sensoriamento Remoto. Manguezais. GEOBIA. Detecção de Mudanças

ABSTRACT

Mangroves are coastal environments that extend along the tropical and subtropical global coastal regions, whose constant monitoring is hampered by its large-scale distribution. With the advent of new computational technologies supported by remote sensing (Google Earth Engine - GEE), this problem has been partially solved. However, some limitations still persist, for example, the use of an image library using only optical sensors, making it difficult to map mangrove forests in areas frequently covered by clouds. Thus, this work aims to evaluate the classification and changes in the mangrove areas of the meso and micro-tidal regions of the Brazilian coastal zone in the last two decades through multi-remote sensor data (optical and microwaves) from geographic object-based image analysis (GEOBIA). Multitemporal images from the Landsat, Alos PalSar, JERS SAR and SRTM series were used. The remote sensing dataset were processed according to the GEOBIA approach, which determines the reduction of an image in homogeneous regions (objects) by grouping sets of pixels with similar characteristics. As a result, it was observed that in 1996 and 2016 the area under study contained 2625,38 km² and 2898,26 km² of mangrove areas, respectively. This demonstrates an increase of 273 km² in mangrove areas. From the analysis of the change detection, it was observed a total increase of 684.55 km², a reduction of 411.7 km² and an unchanged area of 2213.70 km² of mangrove. The classification was validated through statistical analysis of two error matrices (2008 and 2016). The 1996 error matrix presented overall accuracy = 0.92; Kappa index = 0.84; and Tau index = 0.84. For the year 2016, overall accuracy = 0.93; Kappa index = 0.85; and Tau index = 0.85. On the other hand the error matrix for change detection showed an overall accuracy of 78.43%, with a quantity disagreement of 11.86% and an allocation disagreement of 9.71%. Quantifications of mangrove loss was 414 ± 43 km², gains was 590 ± 48 km² and remained mangrove unchanged was 2305 ± 60.3 km². These results demonstrate the effectiveness of using object-oriented classification for mapping and analyzing mangrove dynamics on a large scale. The products obtained in this research can serve as a basis for future work on the dynamics of mangroves, contributing to the improvement of management and preservation of this important ecosystem.

Key-words: Remote Sensing. Mangroves. GEOBIA. Change detection.

LISTA DE ILUSTRAÇÕES

- Figura 1- Mapa ilustrativo da área de estudo com disposição dos manguezais. Notar linha de divisão entre as regiões de Meso e Micromaré, segundo Knoppers et al. (1999), e as principais tipologias costeiras que ocorrem na Região de Mesomaré (RME) e Região de Micromaré (RMI): A – A costa faminta de sedimentos do Nordeste do Brasil; B - O rift costeiro de Camamu – Baía de Todos os Santos; C - Costa Deltáica dominada por onda do leste do Brasil; D - Costa rochosa do sudeste do Brasil. Adaptado de Dominguez (2006)..... 4
- Figura 2- Fluxograma resumindo as principais atividades desenvolvidas durante o desenvolvimento desta pesquisa. 6
- Figura 3- Processos de segmentação e classificação em multiníveis. De cima para baixo temos primeiramente a imagem de referência para os dois períodos mapeados, seguidos abaixo do Nível 1 de segmentação e respectiva classificação das classes Água e Continente, mais abaixo tem-se o nível 2 de segmentação e seguido da classificação de manguezais. A diferença entre os níveis de segmentação pode ser visualizada a partir do tamanho dos objetos imagens. 11
- Figura 4- Sequência de etapas para classificação de imagens. Inicialmente foi criado o N1 de segmentação e classificados as classes Água e Continente, posteriormente foi criado o N2, abaixo do N1, com parâmetros de escala menos que no N1, nesse nível foi classificado a classe Manguezal. O N3 foi criado para otimizar a classificação de N2 e classificar manguezais que se encontravam cobertos por nuvens 12
- Figura 5- Mapa ilustrativo da região de mesomaré (RME) e micromaré (RMI). A esquerda do mapa foram utilizadas imagens SRTM como fundo delimitando a área do Brasil. A tabela a direita representa as imagens Landsat 5 (1996) e Landsat 8 (2016) e suas respectivas classificações em diferentes setores da costa com imagens SAR ao fundo. Em A - Região da ilha do carrapato (MA); B – Foz do rio Piraquê-açu (ES) e C – Ilha Santa Catarina (SC). 19
- Figura 6- Balanço em porcentagem de manguezais entre os dois períodos estudados. Somente em dois estados as perdas foram mais significativas que os ganhos de áreas de mangue..... 22

Figura 7- Mapa de detecção de mudanças com destaques para 8 áreas ao longo da RME e RMI. 1- Delta do Parnaíba (MA/PI), 2 – Região de Macau (RN), 3 – João Pessoa (PB); 4 – Baía de Todos os Santos (BA); 5 – Foz do rio Piraquê-açu (ES); 6 - Baía de Santos (SP); 7- Complexo Estuarino de Paranaguá (PR); 8 – Região da Ilha de Santa Catarina (SC). 23

LISTA DE TABELAS

Tabela 1- Características das imagens SAR, Ópticas e MDE.	7
Tabela 2- Expressões utilizadas para auxiliar na classificação de áreas de manguezais.	13
Tabela 3- Matriz de confusão da classificação para o ano de 1996 com o total de erros e acertos.....	17
Tabela 4- Matriz de confusão da classificação para o ano de 2016 com o total de erros e acertos.....	18
Tabela 5- Áreas de manguezais em 1996 e 2016 por estado e suas respectivas porcentagens em relação ao total.....	20
Tabela 6- Estimativa de mudança das áreas de mangue por estado do sudeste e sul brasileiro entre os anos 2008 e 2016.....	21
Tabela 7. Tabela resumindo a matriz de confusão gerada para a detecção de mudanças para MRE e MRI. A parte superior da tabela faz um comparativo entre os dados obtidos diretamente neste trabalho e os valores ajustados segundo a metodologia de Olofsson et al (2014). A parte inferior da tabela resume os principais dados provenientes da matriz de confusão utilizada para detecção de mudanças dessa dissertação: Acurácia Global (AG); Desacordo Global (DG); Desacordo em Quantidade (DQ) e Desacordo por Alocação (DA).....	24

SUMÁRIO

DEDICATÓRIA	iv
AGRADECIMENTOS	v
EPÍGRAFE	vi
RESUMO	vii
ABSTRACT	viii
LISTA DE ILUSTRAÇÕES	ix
LISTA DE TABELAS	xi
1 INTRODUÇÃO	1
2 ÁREA DE ESTUDO	4
3 MATERIAIS E MÉTODOS	6
3.1 DADOS DE SENSORIAMENTO REMOTO	7
3.2 PROCESSAMENTO DIGITAL DE IMAGENS	8
3.3 SEGMENTAÇÃO E CLASSIFICAÇÃO ORIENTADA A OBJETOS.....	9
3.4 DETECÇÃO DE MUDANÇAS ORIENTADAS AO OBJETO.	13
3.5 AVALIAÇÃO DA CLASSIFICAÇÃO	14
3.6 COLETA DE DADOS PARA AVALIAÇÃO DA CLASSIFICAÇÃO	15
4 RESULTADOS	17
4.1 ACURÁCIA DA CLASSIFICAÇÃO	17
4.2 QUANTIFICAÇÃO DAS ÁREAS DE MANGUEZAIS	18
4.3 DETECÇÃO DE MUDANÇAS NAS ÁREAS DE MANGUEZAIS	20
5 DISCUSSÕES	25
6 CONCLUSÃO	27
REFERÊNCIAS	28

1 INTRODUÇÃO

Os manguezais são ambientes costeiros que se estendem ao longo da faixa tropical e subtropical do globo em diversos países (Schaeffer-Novelli 1995). No ano 2000 a área estimada de ocorrência de manguezais era de 137.760 km² ao longo de 118 países. O Brasil destaca-se como o terceiro país em extensão de áreas de mangue com 9.626,83 km², o que representava 7% do total (Giri *et al.* 2011). Essa ampla distribuição dos manguezais é um dos principais fatores que dificultam o mapeamento e monitoramento deste ambiente, que para ser executado requer tempo para coleta de dados em campo, intérpretes com formação multidisciplinar e uma demanda por hardware e software de bom desempenho.

O avanço tecnológico sempre foi um importante aliado no mapeamento de manguezais, no sentido de melhoria da qualidade das imagens, que no início eram feitas através de fotografias aéreas (Terchunian *et al.* 1986) e imagens de radar analógicas (Herz 1991, Singhroy 1996). Mais recentemente, os mapeamentos são realizados através de imagens digitais de sensores remotos com resolução espacial cada vez melhores provenientes de satélites (Everitt & Judd 1989, Kovacs *et al.* 2005), aeronaves (Salum *et al.* 2020, Souza-Filho *et al.* 2011) e veículos aéreos não tripulados – VANTs (Santos 2012, Yaney-Keller *et al.* 2019, Zimudzi *et al.* 2019).

Diferentes técnicas de processamento digital de imagens têm sido utilizadas para realçar as áreas de manguezal, tal como índices de vegetação (Jensen *et al.* 1991), análise de principal componentes e razão de bandas (Green *et al.* 1998) e fusão de dados multisensores (Rodrigues & Souza-Filho 2011, Souza Filho & Paradella 2005). Com o advento de imagens de sensores remotos com resoluções espaciais e espectrais cada vez melhores, abordagens de classificação tem evoluído a partir daquelas fundamentadas em pixel (Ramsey Iii *et al.* 1998) até às Análises de Imagens Baseadas em Objetos Geográficos – GEOBIA (Blaschke 2010, Nascimento Jr *et al.* 2013).

A GEOBIA é uma técnica relativamente recente de classificação. Este método baseia-se na divisão da imagem digital em regiões homogêneas e contínuas, denominadas de objetos geográficos (Flanders *et al.* 2003). Uma das grandes vantagens da abordagem GEOBIA é a possibilidade de utilização de diferentes fontes de dados de sensores remotos (e.g. reflectância, retroespalhamento, elevação, temperatura), além de explorar características da imagem que não são apenas as “cores”, como tom, padrão, forma e contexto para delimitar regiões com características semelhantes (Blaschke *et al.* 2014).

A nova tendência inclui também a capacidade de armazenamento e processamento computacional das coleções de imagens em nuvens, como a plataforma *Google Earth Engine* – GEE (Diniz *et al.* 2019, Souza & Azevedo 2017). Apesar de todos os avanços, algumas limitações ainda perduram, como a ausência de bibliotecas de imagens de radares de abertura sintética (SAR) nas plataformas de dados, o que limita o mapeamento de áreas tropicais, cujos litorais são frequentemente colonizados por mangues, constantemente cobertos por nuvens.

As campanhas de levantamentos de áreas de mangue no Brasil ocorrem desde a década de 70, porém a maioria dos trabalhos o faz de forma fragmentada, através do mapeamento de áreas costeiras restritas, como estuários, baías e planícies de marés. Herz (1991) foi pioneiro no mapeamento contínuo de manguezais no Brasil, utilizando imagens de radar adquiridas entre 1972 e 1975. Ele mapeou uma área de 10.123,76 km² de manguezais ao longo de todo o litoral brasileiro. Posteriormente, Magris & Barreto (2010) estimaram as áreas de mangue do Brasil em aproximadamente 11.143,97 km², a partir da interpretação visual de imagens Landsat-5 TM adquiridas entre 2007 e 2009. O Atlas de Manguezais do Brasil estimou uma área de mangue de 13,989 km² a partir da interpretação de imagens Landsat-8 OLI do ano de 2013 (ICMBio 2018). Mais recentemente, foi realizado um mapeamento multi-anual dos manguezais brasileiros, de 1985 até 2018, utilizando imagens óptica da série Landsat na plataforma GEE, constatando que em 2018 o Brasil continha aproximadamente 9.940,00 km² de área de manguezal (Diniz *et al.* 2019).

Superado o desafio de mapear os manguezais brasileiros, uma nova questão emerge: como as mudanças nas áreas de mangue vem ocorrendo ao longo de todo o litoral brasileiro? Apesar do Brasil apresentar 120 unidades de conservação que contém manguezais, cobrindo uma área de 12.114,44 km² (ICMBio 2018) o que representa 87% de todo ecossistema no Brasil, é preciso monitorar esses ambientes constantemente. Nesse quesito, a detecção de mudanças em áreas de manguezais é de suma importância para o monitoramento e suporte à tomada de decisões de políticas que visam a proteção e preservação do ecossistema manguezal, que desempenha diversas funções naturais não só de importância ecológica (Alongi 2008), mas também social e econômica (Glaser *et al.* 2010, Grasso 2002), pois a maioria da população ribeirinha que vive no seu entorno, muitas vezes dependem da retirada e venda dos elementos da fauna e flora desses ecossistemas para o sustento de suas famílias (ICMBio 2018).

Para a região de macromaré da costa norte do Brasil, Nascimento Jr *et al.* (2013) mostraram que os manguezais estavam em expansão entre 1996 e 2008. Diniz *et al.* (2019) ratificaram esta tendência para o período e observaram que a partir de 2008 até 2018 a área de

manguezal manteve-se relativamente estável na costa norte brasileiras. Este trabalho tem como objetivo avaliar a classificação e as mudanças multitemporais nas áreas de mangues das regiões de meso e micromaré da Costa Nordeste, Sudeste e Sul brasileira nas últimas duas décadas, a partir de dados multisensores (SAR, óptico e elevação). O mapeamento dessas regiões, em conjunto, a partir da abordagem GEOBIA será pioneiro de e grande importância para o gerenciamento costeiro, em especial das áreas de manguezais.

2 ÁREA DE ESTUDO

A zona costeira brasileira é compartimentada em três grandes regiões, com base nas amplitudes de marés: Regiões de Macro (do Oiapoque-AP até –Foz do rio Parnaíba MA-PI); Meso (Foz Parnaíba até o sul do estado da Bahia) e Micromaré (Sul do estado da Bahia até Chuí-RS), todas sob regime de maré semi-diurna (Knoppers *et al.* 1999). A área de estudo engloba as planícies costeiras de mesomares que se estendem ao longo da região nordeste do Brasil, passando pelas planícies de micromarés das regiões sudeste e sul do Brasil, distribuídas por aproximadamente 4.780 km ao longo do litoral. A figura 1 ilustra a área de estudo com a disposição dos manguezais ao longo do litoral brasileiro.




Figura 1- Mapa ilustrativo da área de estudo com disposição dos manguezais. Notar linha de divisão entre as regiões de Meso e Micromaré, segundo Knoppers *et al.* (1999), e as principais tipologias costeiras que ocorrem na Região de Mesomaré (RME) e Região de Micromaré (RMI): A – A costa faminta de sedimentos do Nordeste do Brasil; B - O rift costeiro de Camamu – Baía de Todos os Santos; C - Costa Deltáica dominada por onda do leste do Brasil; D - Costa rochosa do sudeste do Brasil. Adaptado de Dominguez (2006).

A Costa Nordeste apresenta características de tipo de costa com energia mista e clima semiárido (Dominguez 2006). Essa costa apresenta características de uma “costa faminta” em virtude do baixo volume de sedimentos recebidos do continente, fato esse que tende a ocasionar um recuo da costa a longo prazo. O litoral apresenta características únicas que incluem extensos sedimentos do *shoreface* superior, “beach rocks” e falésias ativas esculpidas

nos sedimentos da Formação Barreiras reativadas por falhas neotectônicas (Bezerra *et al.* 2014).

O Rift Costeiro de Camamu - Baía de Todos os Santos aparece como reflexo de fenômenos geológicos ocorridos há milhões de anos. Nele a erosão diferencial das rochas sedimentares menos resistentes das bacias de rift de Reconcavo - Camamu exumou uma estrutura de blocos falhados que compõem a arquitetura dessas bacias e quando invadidos pelo mar, durante as elevações do nível do mar do Quaternário, deram origem a algumas das maiores baías do Brasil. A sedimentação nessa região é fortemente influenciada por marés (Dominguez 2006).

Dominguez (2006) descreve a Costa Sudeste como dominada por ondas e segundo (Strahler & Strahler 1991) seu clima é caracterizado como litorâneo úmido. Esta região caracteriza-se como uma costa deltaica dominada por ondas, provenientes da combinação de grandes bacias de drenagem com altas altitudes e alta precipitação, resultando em grandes aportes de sedimentos para os rios. As costas rochosas também estão presentes dando origem à morfologia característica dessa região. Este terreno montanhoso sofreu influência durante os movimentos tectônicos no Neógeno. A inundação dessa topografia montanhosa durante a elevação do nível do mar no Quaternário deu origem a uma zona costeira caracterizada por inúmeras ilhas barreiras e baías, como é o caso da Baía de Guanabara (Dominguez 2006).

Na Costa Sul do Brasil, os processos eólicos têm papel significativo e são consequências diretas dos efeitos combinados do aumento da velocidade e frequência do vento durante a estação seca de clima subtropical úmido (Dominguez 2006, Strahler & Strahler 1991) . Esta região é caracterizada por uma extensa planície de sedimentos quaternários, caracterizados como barreiras costeiras progradantes (Dillenburg *et al.* 2017).

3 MATERIAIS E MÉTODOS

A figura 2 apresenta de forma resumida as diferentes etapas de pesquisa desenvolvidas ao longo deste trabalho.

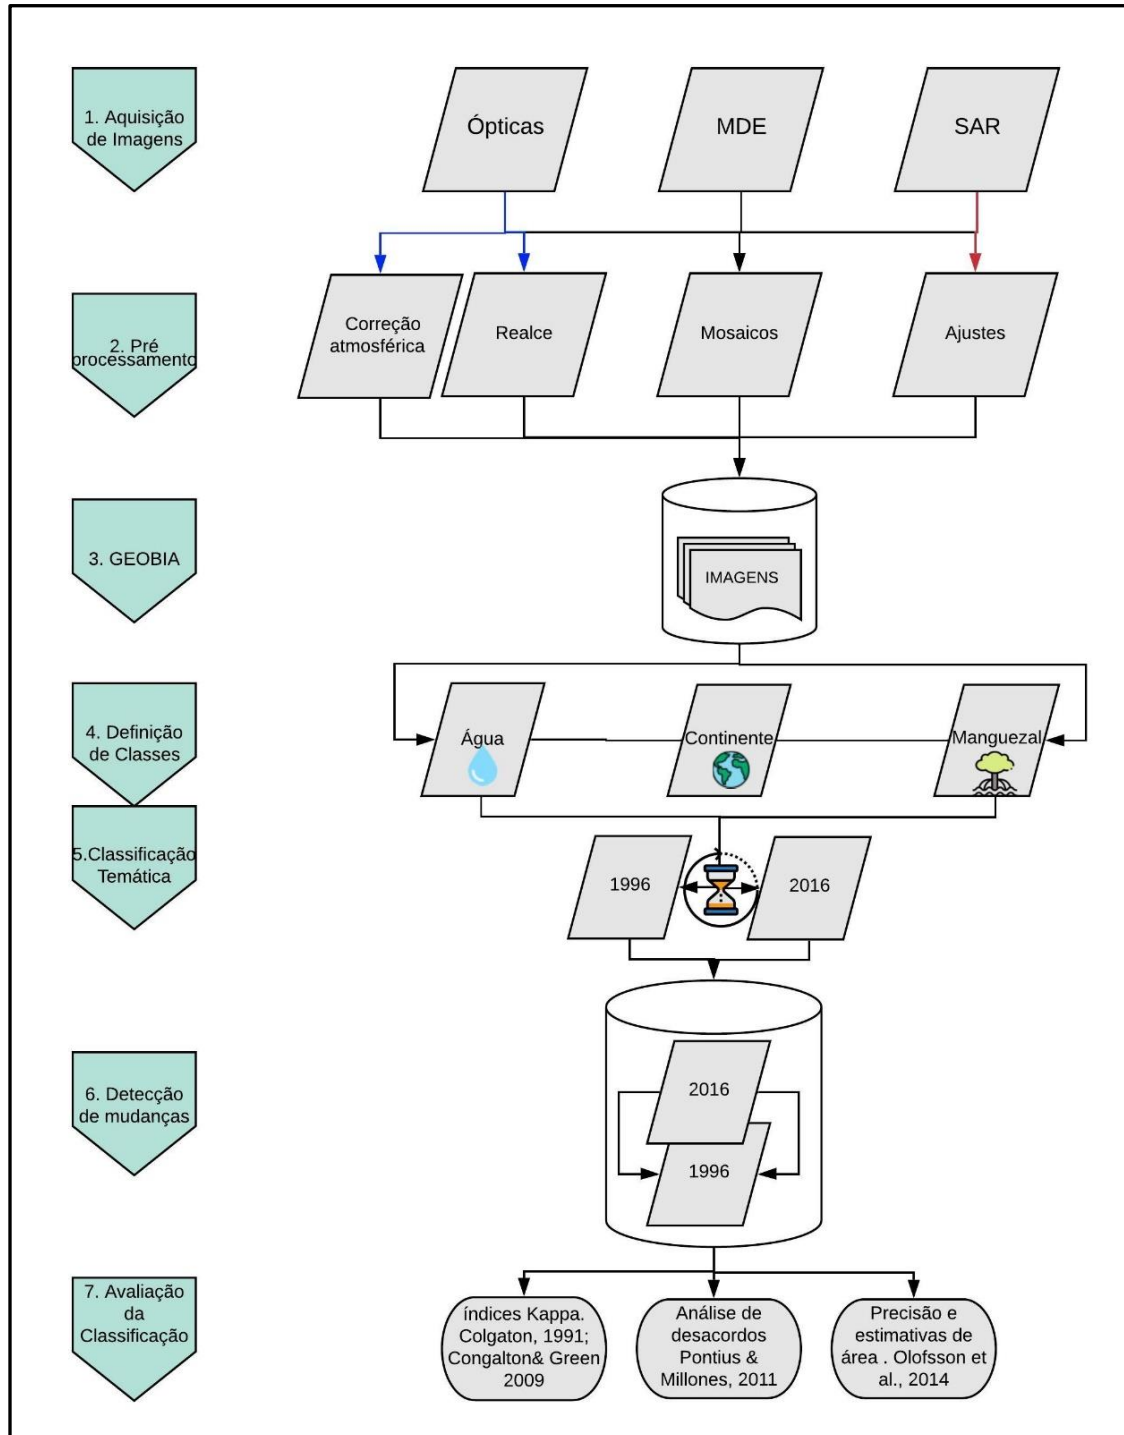


Figura 2- Fluxograma resumindo as principais atividades desenvolvidas durante o desenvolvimento desta pesquisa.

3.1 DADOS DE SENSORIAMENTO REMOTO

Os dados de sensores remotos utilizadas neste trabalho (SAR; Óptica e Modelo Digital de Elevação) são provenientes de diferentes satélites. As imagens de SAR foram adquiridas na plataforma digital do Jaxa EORC (https://www.eorc.jaxa.jp/ALOS/en/palsar_fnf/data/index.htm). As imagens de 2016 são oriundas do satélite Alos, sensor PalSAR com resolução espacial de 25m nas polarizações HH e HV. Enquanto as imagens SAR referentes ao ano de 1996 são provenientes do satélite JERS-1, sensor SAR, na polarização HH e com 30m de resolução espacial.

As imagens ópticas são provenientes da série Landsat e foram adquiridas na plataforma *Earth Explorer* (<https://earthexplorer.usgs.gov/>). Imagens do sensor *Operational Land Imager* (OLI) do satélite Landsat-8 foram adquiridas para o ano de 2016 e imagens do sensor *Thematic Mapper* (TM) do satélite Landsat-5 foram adquiridas para o ano de 1996. Ambos sensores fornecem imagens com resolução espacial de 30m.

Os Modelos Digitais de Elevação (MDE) utilizados também foram adquiridos de fontes distintas. Foram utilizados MDEs do Alos PalSAR (2016) adquiridas na plataforma *Alaska Facility* (<https://search.asf.alaska.edu/#/>) com resolução espacial de 25m e da missão SRTM (*Shuttle Radar Topography Mission – 2000*) com resolução espacial de 30m adquirido na plataforma TOPODATA do INPE (<http://www.webmapit.com.br/inpe/topodata/>).

Foram adquiridas 61 imagens SAR, 32 imagens Ópticas e 52 MDE para cada ano avaliado, totalizando 145 imagens. Vale ressaltar que todas as imagens foram adquiridas de maneira gratuita nas plataformas acima mencionadas. A Tabela 1 sumariza as principais características dos sensores utilizados neste trabalho.

Tabela 1- Características das imagens SAR, Ópticas e MDE.

(continua)

Satélite/Sensor	Tipo	Comprimento das bandas/faixas	Polarização	Resolução espacial
ALOS/PALSAR	SAR	L (23,5 cm)	HV	10 m
JERS - 1	SAR	L (23,5 cm)	HH	30 m
MDE/SRTM	SAR	C (5,6 a 7,5 cm);	--	30 m

(conclusão)

Satélite/Sensor	Tipo	Comprimento das bandas/faixas	Polarização	Resolução espacial
MDE ALOS/PALSAR	SAR	L (23,5 cm)	HH	30 m
Landsat 5 - TM	Óptico	B1 (0,45-0,52 μm); B2 (0,52-0,60 μm); B3 (0,63-0,69 μm); B4 (0,76-0,90 μm); B5 (1,55-1,75 μm)	--	30 m
		B6 (10,4-12,5 μm)		120 m
		B7 (2,08-2,35 μm)		30 m
Landsat 8 - OLI	Óptico	B1 (0.43 - 0.45 μm) B2 (0.45 - 0.51 μm) B3 (0.53 - 0.59 μm) B4 (0.64 - 0.67 μm) B5 (0.85 - 0.88 μm) B6 (1.57 - 1.65 μm) B7(2.11 - 2.29 μm)	--	30 m
		B8 (0.50 - 0.68 μm)		15 m
		B9 (1.36 - 1.38 μm)		30 m

3.2 PROCESSAMENTO DIGITAL DE IMAGENS

Os dados de sensores ópticos foram submetidas ao pré-processamento, no que consistiu a correção radiométrica e atmosférica no módulo ATCOOR do *software* PCI Geomatica, para calibrar as imagens, convertendo dados de números digitais para reflectância do solo (*ground reflectance*). Nas imagens SAR foram realizados registros em relação as imagens ópticas, e os valores digitais dos dados SAR foram convertidos para retroespalhamento em decibéis (dB). Os mosaicos referentes ao dado SAR foram confeccionados no *software* ENVI 5.0. Já os mosaicos de dados ópticos foram feitos no módulo Ortho Engine do *software* PCI Geomática e o mosaico dos dados MDE foram confeccionados no *software* Global Mapper 18.0.

Para classificação das imagens utilizou-se o *software* Definiens eCognition 9.0. Este *software* realiza uma análise orientada a objetos geográficos de acordo com parâmetros de escala, heterogeneidade e atribuições de peso para cada banda espectral no processo de segmentação, o qual podem ser aplicadas para os diferentes sensores (Flanders *et al.* 2003). Além disso, também oferece uma gama de algoritmos adaptados aos diferentes aspectos da análise de imagens, como os de segmentação multiresolução (Blaschke 2010). Os algoritmos

utilizados para classificação variam desde a análise de vizinhos mais próximos, a base de amostra (*sample-based*), função de pertinência, utilizando a lógica fuzzy, ou mesmo uma análise orientada ao contexto especializada (Walter 2004). A análise pode ser implementada com base em condições, amostras ou uma combinação de ambos (Blaschke 2010, Walter 2004).

É importante ressaltar a utilização de GEOBIA pelas vantagens da utilização combinada da qualidade das interpretações humanas com a capacidade do quantitativo computacional (Souza-Filho *et al.* 2019).

Antes de realizar a classificação propriamente dita, o *software* realiza o processo de segmentação, que tem como produto a determinação de objetos-imagens. Nesse processo são agrupados os conjuntos de pixels com características similares, levando em consideração os aspectos espectrais e de forma dos objetos (compactidade e suavidade), textura e tamanho dos objetos (Blaschke & Kux 2005, Flanders *et al.* 2003, Gonçalves *et al.* 2007).

3.3 SEGMENTAÇÃO E CLASSIFICAÇÃO ORIENTADA A OBJETOS

Os diferentes dados (SAR, ópticos e MDE) foram processadas em conjunto segundo o algoritmo segmentação multiresolução. No processo de segmentação foram utilizadas todas as bandas dos diferentes sensores, porém as bandas receberam pesos diferentes com a finalidade de extrair o melhor de cada sensor, potencializando assim o processo de segmentação. Adaptando a metodologia proposta por Nascimento Jr *et al.* (2013) foram utilizados três níveis de segmentação, os quais também receberam diferentes pesos de bandas de acordo com o alvo específico em cada um deles. No nível 1 de segmentação foi dada ênfase a separação Água-Continente. Nesse nível foram utilizados na segmentação parâmetro escala igual a 50 e os maiores pesos (igual a 10) foram atribuídos para os dados SAR (polarizações HH e/ou HV), que não são afetados pela presença de nuvens, permitindo uma melhor definição da linha de costa conforme definido por (Nascimento Jr *et al.* 2013). As bandas de elevação receberam peso 5 e as de sensores ópticos receberam peso 1.

Para a classificação automática das imagens foi realizada uma classificação não supervisionada segundo o algoritmo “*Classification*” a partir de funções específicas contidas nas descrições das classes. Os parâmetros de classificação utilizados no nível 1 foram definidos principalmente com base nos valores de retroespalhamento (em decibel-dB) dos dados SAR, representados na “Expressão 1” (tabela 2), os quais foram fundamentais para a

definição da linha de costa e diferenciação entre essas duas classes iniciais (Massa d'água e Continente).

No nível 2 de segmentação o alvo era diferenciar as florestas de mangue das demais vegetações, para isso utilizou-se parâmetro escala igual a 10 e pesos maiores foram atribuídos justamente para as bandas dos sensores ópticos em detrimento aos dados SAR (Infravermelho Próximo (NIR) -5; Infravermelho de ondas curtas/infravermelho (SWIR/IR) -3; demais bandas -1). Os pesos foram escolhidos a partir de uma abordagem heurística de tentativa e erro para tentar definir melhor os objetos específicos que foram efetivamente diferenciados em bandas espectrais predeterminadas (Baatz & Schape 2000). Este nível foi criado abaixo do nível 1, dessa forma os objetos imagens do nível 2 estão contidos nos objetos imagens do nível 1, apresentando menor área, maior quantidade de objetos e conseqüentemente maior grau de detalhamento na segmentação.

Os parâmetros utilizados para classificação do manguezal se basearam nos valores médios de reflectância das bandas espectrais do vermelho, infra-vermelho próximo, e infra-vermelho (Mean B3, B5 e B7 respectivamente) do sensor óptico Landsat 5 TM e das bandas 4,5,6 (vermelho, infra-vermelho próximo e infravermelho de ondas curtas respectivamente) do sensor OLI-8 através da "Expressão 2" (tabela 2). A figura 3 ilustra os processos acima citados para melhor visualização. A utilização do MDE isolado também foi uma alternativa encontrada para otimizar a classificação, pois com isso foi possível para limitar a ocorrência de manguezais através da altura dossel das florestas de mangue.

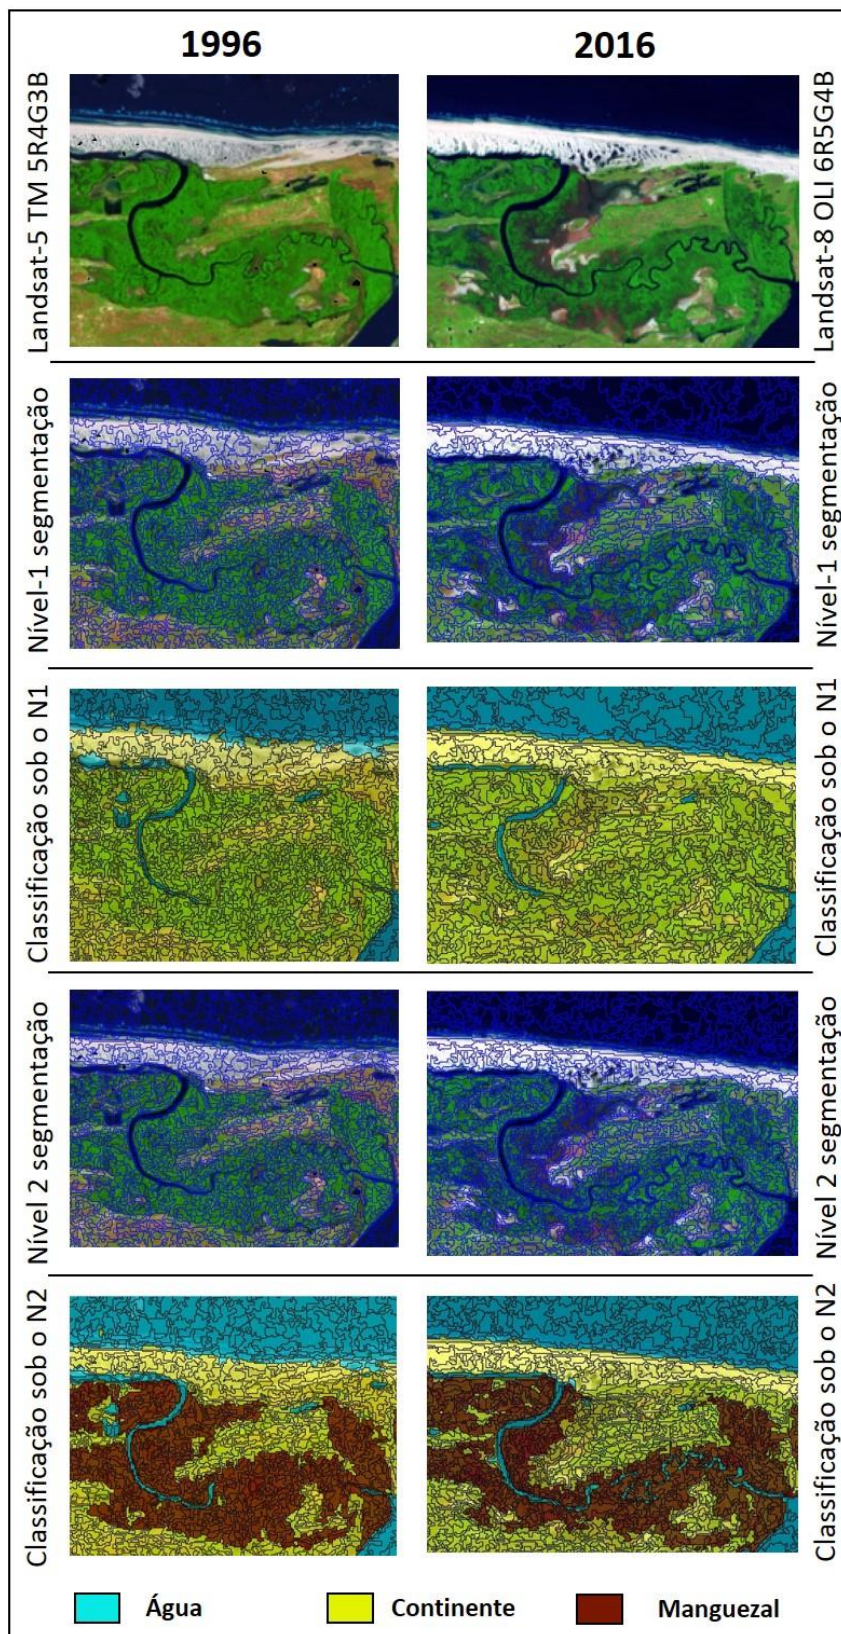


Figura 3- Processos de segmentação e classificação em multiníveis. De cima para baixo temos primeiramente a imagem de referência para os dois períodos mapeados, seguidos abaixo do Nível 1 de segmentação e respectiva classificação das classes Água e Continente, mais abaixo tem-se o nível 2 de segmentação e seguido da classificação de manguezais. A diferença entre os níveis de segmentação pode ser visualizada a partir do tamanho dos objetos imagens.

O nível 3 de segmentação foi uma cópia do nível 2, dessa forma os atributos de segmentação são iguais. Este nível foi criado com intuito de aprimorar a classificação. Nele foram realizadas operações de relações de vizinhança entre os objetos imagens para classificação de manguezal abaixo de nuvens e para remoção algumas classificações de mangue que estavam equivocadas, em virtude de confusão das respostas espectrais dos alvos.

A “expressão 3” (tabela 2) é constituída por uma razão média entre os dados SAR e MDE e foi de fundamental importância no mapeamento de manguezais abaixo das nuvens, assim como a expressão 4. A figura 4 ilustra a sequência de segmentação e classificação para os 3 níveis acima citados e em seguida a tabela 2 apresenta as expressões que auxiliaram nas classificações e edições das classificações.

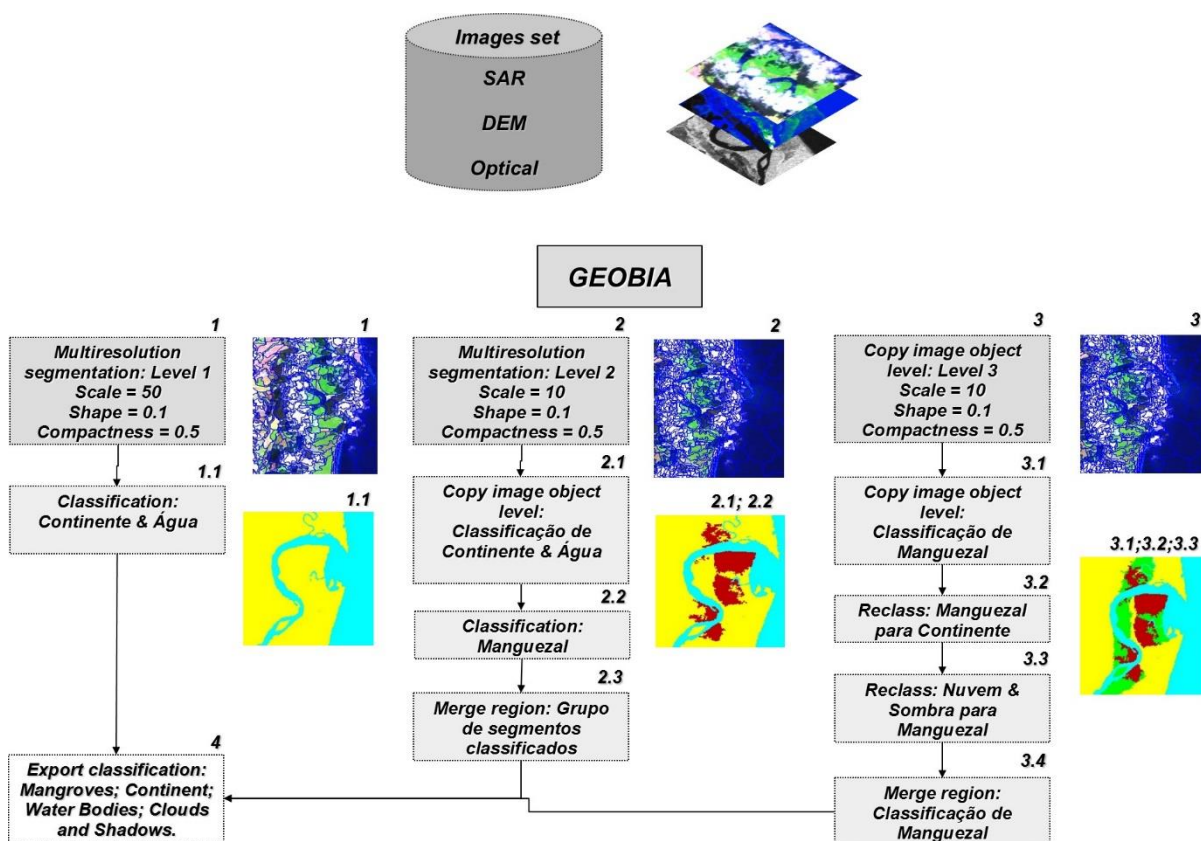


Figura 4- Sequência de etapas para classificação de imagens. Inicialmente foi criado o N1 de segmentação e classificados as classes Água e Continente, posteriormente foi criado o N2, abaixo do N1, com parâmetros de escala menos que no N1, nesse nível foi classificado a classe Manguezal. O N3 foi criado para otimizar a classificação de N2 e classificar manguezais que se encontravam cobertos por nuvens

Tabela 2- Expressões utilizadas para auxiliar na classificação de áreas de manguezais.

DESCRIÇÃO	EXPRESSÃO (1996)	EXPRESSÃO (2016)
EXPRESSÃO 1	$10 \cdot \log (\text{Mean HH})$	$10 \cdot \log (\text{Mean HV})$
EXPRESSÃO 2	$\frac{[(\text{Mean B5} - \text{Mean B3}) / (\text{Mean B5} + \text{Mean B3})] + \text{Mean B7}}$	$\frac{[(\text{Mean B5} - \text{Mean B4}) / (\text{Mean B5} + \text{Mean B4})] + \text{Mean B6}}$
EXPRESSÃO 3	$\text{Mean HH} / \text{Mean MDE}$	$\text{Mean HV} / \text{Mean MDE}$
EXPRESSÃO 4	$10 \cdot \log (\text{Mean HH}) / \text{MDE}$	$10 \cdot \log (\text{Mean HV}) / \text{MDE}$

3.4 DETECÇÃO DE MUDANÇAS ORIENTADAS AO OBJETO.

O processamento para detecção de mudanças também foi feito no *software* Definiens Ecognition. A metodologia adotada foi proveniente de adaptações dos trabalhos de Descleé *et al.* (2006); Nascimento Jr *et al.* (2013) e Souza-Filho *et al.* (2018). Primeiramente, foram exportadas as duas classificações (1996 e 2016) em formato *raster*. Em seguida atribuíram-se novos parâmetros de segmentação e classificação. Após isso foram criadas 5 novas classes, são elas: Mangue 1996; Mangue 2016; Ganho de Mangue; Perda de Mangue; Mangue Inalterado (Descleé *et al.* 2006, Nascimento Jr *et al.* 2013, Souza-Filho *et al.* 2018).

Os parâmetros de segmentação utilizados na segmentação multiresolução foram os seguintes: parâmetro de escala = 10, forma = 0,1 e compassidade = 0,5. Para a detecção de mudança, os arquivos matriciais (“*rasters*”) dos mosaicos dos anos 1996 e 2016 receberam pesos iguais a 1. Para classificação foram utilizadas as repostas dos números digitais das imagens que assumiam dois valores 0 (ausência de dados) e 255 (presença de Mangue). Áreas de mangue que somente estavam presentes na classe “Mangue 1996” (Mangue 1996 = 255 e Mangue 2016 = 0) foram classificadas como “Perda de Mangue”. Da mesma forma áreas de mangue que somente estavam presentes na classe “Mangue 2016” (Mangue 1996 = 0 e Mangue 2016 = 255) foram classificadas como “Ganho de Mangue”, e as áreas em que ambas imagens apresentavam número digital igual a 255 foram classificadas como Mangue inalterado (Mangue 1996 = 255 e Mangue 2016 = 255). Após a definição das classes, os objetos que as representavam foram exportados para ambiente SIG em formato vetorial com objetivo de quantificar as áreas de mangue e gerar mapas temáticos com os resultados da classificação orientada a objetos.

3.5 AVALIAÇÃO DA CLASSIFICAÇÃO

O processo de validação dos resultados obtidos é muito importante para avaliar a precisão das classificações a partir de dados de referência. A metodologia clássica utiliza matriz de confusão (ou matriz de erro) que são tabelas contendo os erros e acertos da classificação, associados a diferentes índices, como as acurácias do usuário e produtor (Story & Congalton 1986) índice Kappa (Congalton 1991), coeficiente Kappa geral e Kappa por classe (Congalton & Green 2019). Porém, mais recentemente, a metodologia de Pontius Jr & Millones (2011) ganhou notoriedade por levar em consideração os desacordos em quantidade e alocação (Congalton & Green 2019, Pontius Jr & Millones 2011, Story & Congalton 1986).

A metodologia proposta por Pontius Jr & Millones (2011) coloca em cheque a veracidade dos resultados encontrados nos índices Kappa. Pontius Jr & Millones (2011) afirmam que o índice kappa não são suficientemente bons para avaliar a classificação de mapas temáticos e listam 3 motivos para que a comunidade científica abandone os estudos de validação através desses índices: 1) Cada índice Kappa é uma razão que pode introduzir problemas no cálculo e na interpretação; 2) É mais útil entender os dois componentes da discordância (quantidade e alocação) do que ter uma única estatística resumida de concordância ao interpretar resultados e; 3) os índices Kappa tentam comparar a precisão observada em relação a uma linha de base de precisão esperada devido à aleatoriedade, porém nas aplicações vistas pelos autores a aleatoriedade é uma linha de base desinteressante, irrelevante e/ou enganosa (Pontius Jr & Millones 2011).

Com isso Pontius Jr & Millones (2011) sugerem que os estudos sejam avaliados através de metodologia mais simples e eficaz que são encontradas justamente nas análises de erros de desacordo de quantidade e alocação. Abaixo seguem as definições e conceitos segundo os autores. O desacordo em quantidade é definido como a quantidade de diferença entre o mapa de referência e um mapa de comparação devido à correspondência menos que perfeita nas proporções das classes. Já o desacordo por alocação é relacionado com a diferença entre o mapa de referência e um mapa de comparação devido a pixels das classes mal alocados espacialmente. O desacordo de alocação é sempre um número par de pixels. Cada par consiste em um pixel de omissão para uma classe específica e um pixel de comissão para a mesma classe. Um pixel é chamado de omissão para uma classe quando está presente no mapa de referência e não está no mapa de comparação. Um pixel é chamado de comissão quando está presente no mapa de comparação e não está no mapa de referência (Pontius Jr & Millones 2011).

A análise da detecção de mudança multitemporal também é de suma importância nos estudos que envolvem mudanças de uso e cobertura de terra para que medidas de gerenciamento e suporte sejam aplicadas de maneira correta e eficaz. Um mapa de mudanças é a representação espacialmente explícita de mudanças temporais, e essas informações espaciais podem ser utilizadas para calcular a área total mapeada ou a proporção da área de mudanças para a região de interesse (Olofsson *et al.* 2014). A avaliação da precisão aborda questões relacionadas a quão bem os locais das mudanças mapeadas correspondem às áreas reais de mudança. A metodologia adotada para avaliar esse dado será conforme proposto por Olofsson *et al.* (2014) que apresenta uma nova abordagem através de boas práticas para estimativas de áreas. Essa metodologia busca realizar avaliações de precisão e de estimativa de área com base em amostras de referência (Olofsson *et al.* 2014).

A avaliação de precisão busca identificar os erros da classificação e os dados das amostras podem ser utilizados para estimar e acurácia, bem como as incertezas dessas estimativas (Olofsson *et al.* 2014). Segundo os autores a premissa fundamental da metodologia de boas práticas recomendadas é que o mapa de alterações esteja sujeito a uma avaliação de precisão com base em amostras de informações sobre alterações de qualidade mais alta (ou seja, a classificação de referência).

Segundo Olofsson *et al.* (2014) a metodologia de avaliação da precisão consiste em três componentes principais: o design da resposta, o design da amostra e a análise (Stehman & Czaplewski 1998). O design da resposta abrange todos os aspectos do protocolo que levam a determinar se o mapa e as classificações de referência estão de acordo. Como muitas vezes é impraticável aplicar o design da resposta a toda região de interesse, é amostrado um subconjunto da área. O design de amostragem é o protocolo para selecionar esse subconjunto da região de interesse. A análise inclui protocolos para definir como quantificar a precisão, juntamente com as fórmulas e a estrutura de inferência para estimar a precisão e a área, assim como quantificar a incerteza dessas estimativas (Olofsson *et al.* 2014).

3.6 COLETA DE DADOS PARA AVALIAÇÃO DA CLASSIFICAÇÃO

Para confecção das matrizes de erro há necessidade primeiro de serem obtidos pontos de controle para se verificar as estatísticas de erros e acertos nos mapas. Para isso utilizou-se um algoritmo no *software* ArcGIS 10.6 para sortear pontos de controles de forma aleatória e suficientemente representativos ao longo de toda área de trabalho. Dessa forma para avaliação das classificações de cada período (1996; 2016) foram utilizados um total de 1600 pontos

divididos em duas classes principais: “Mangue” e “Outros” para facilitar a interpretação dos dados. Já para a detecção de mudanças foram sorteados 1400 pontos divididos nas 3 classes de detecção de mudanças que são: Perda de Mangue; Ganho de Mangue; e Mangue inalterado conforme citado no tópico 3.4.

4 RESULTADOS

4.1 ACURÁCIA DA CLASSIFICAÇÃO

Para a validação da classificação foram utilizados um total de 1600 pontos de controle para cada um dos anos classificados (1996 e 2016). Deste total, para cada ano, 800 pontos foram coletados em área de manguezal e 800 pontos nas demais classes, que foram aqui agrupadas e definidas como classe “Outros”.

Para o ano de 1996, do total de 1600 pontos distribuídos ao longo de toda área de trabalhos 1470 pontos foram corretamente classificados, o equivalente a uma exatidão geral de 92%. Os pontos equivocados somaram 130 ou 8%. Dos 800 pontos sorteados em áreas de ocorrência de manguezais 112 não concordaram com os dados de referência, já para os 800 pontos demarcados na classe “Outros” os resultados foram melhores, somente 18 pontos foram classificados de forma errônea.

Alguns índices foram utilizados com a finalidade de verificar a acurácia da classificação. Para o índice Kappa geral foram obtidos, em 1996, o valor de 0,84. O índice Kappa por classes atingiu valores de 0,75 para a classe Manguezal e 0,95 para a classe “Outros”. Para Índice Tau o valor obtido foi de 0,84, o que indicou que mais de 84% objetos foram classificados corretamente do que seria esperado, de acordo com a atribuição aleatória (Tabela 3).

Tabela 3- Matriz de confusão da classificação para o ano de 1996 com o total de erros e acertos

Classificação	Manguezal	Outros	Total	Acurácia do usuário	Erro de comissão
Manguezal	688	18	706	97,45	2,55
Outros	112	782	894	87,47	12,53
Total	800	800	1600		
Erro de omissão	14,0	2,25			
Acurácia do produtor	86,0	97,75			
Kappa por classe	0,75	0,95			
Exatidão geral = 0,92				Índice kappa = 0,84	Índice Tau = 0,84

Ao analisarmos esses dados conforme a metodologia proposta por Pontius Jr & Millones (2011), a mesma matriz apresenta desacordo total de 8,13% os quais são distribuídos

entre o desacordo em quantidade (5,88%) e o desacordo de alocação (2,25%) para as duas classes.

Para o ano de 2016, dos 1600 pontos coletados em área de manguezal, 1482 ou 93 % foram classificados corretamente, enquanto que 118 pontos ou 7% não concordaram com os dados de referência. Dos 800 pontos sorteados em áreas de mangue 86 pontos não obtiveram sucesso na classificação, já na classe “Outros” um total de 32 pontos foram classificados de forma incorreta. Para este ano foram obtidos o índice Kappa geral no valor de 0,85. O índice Kappa por classes atingiu valores de 0,80 para a classe Manguezal e 0,91 para a classe “Outros”. O Índice Tau obtido foi com o valor de 0,84. A tabela 4 apresenta os dados acima.

Tabela 4- Matriz de confusão da classificação para o ano de 2016 com o total de erros e acertos

Classificação	Manguezal	Outros	Total	Acurácia do usuário	Erro de comissão
Manguezal	714	32	746	95,71	4,29
Outros	86	768	854	89,93	10,07
Total	800	800	1600		
Erro de omissão	10,75	4,0			
Acurácia do produtor	89,25	96,0			
Kappa por classe	0,8	0,91			
Exatidão geral = 0,93				Índice kappa = 0,85	Índice Tau = 0,85

Para o referido ano, a matriz de erro também foi analisada segundo Pontius Jr & Millones (2011). O total de desacordo foi menor que o encontrado para 1996, em 2016 os desacordos somaram 7,38%, divididos em 3,38 por desacordo em quantidade e 4% por desacordo em alocação.

4.2 QUANTIFICAÇÃO DAS ÁREAS DE MANGUEZAIS

A partir da metodologia desenvolvida foi possível classificar e quantificar as áreas de mangue nos períodos de 1996 e 2016 (Figura 5). Constatou-se que em 1996 a área de estudo continha 2.625,38 km², passando para 2.898,26 km² de florestas de mangue em 2016. Ou seja, houve aumento no total de áreas de mangue para a região estudada de aproximadamente 273 km².

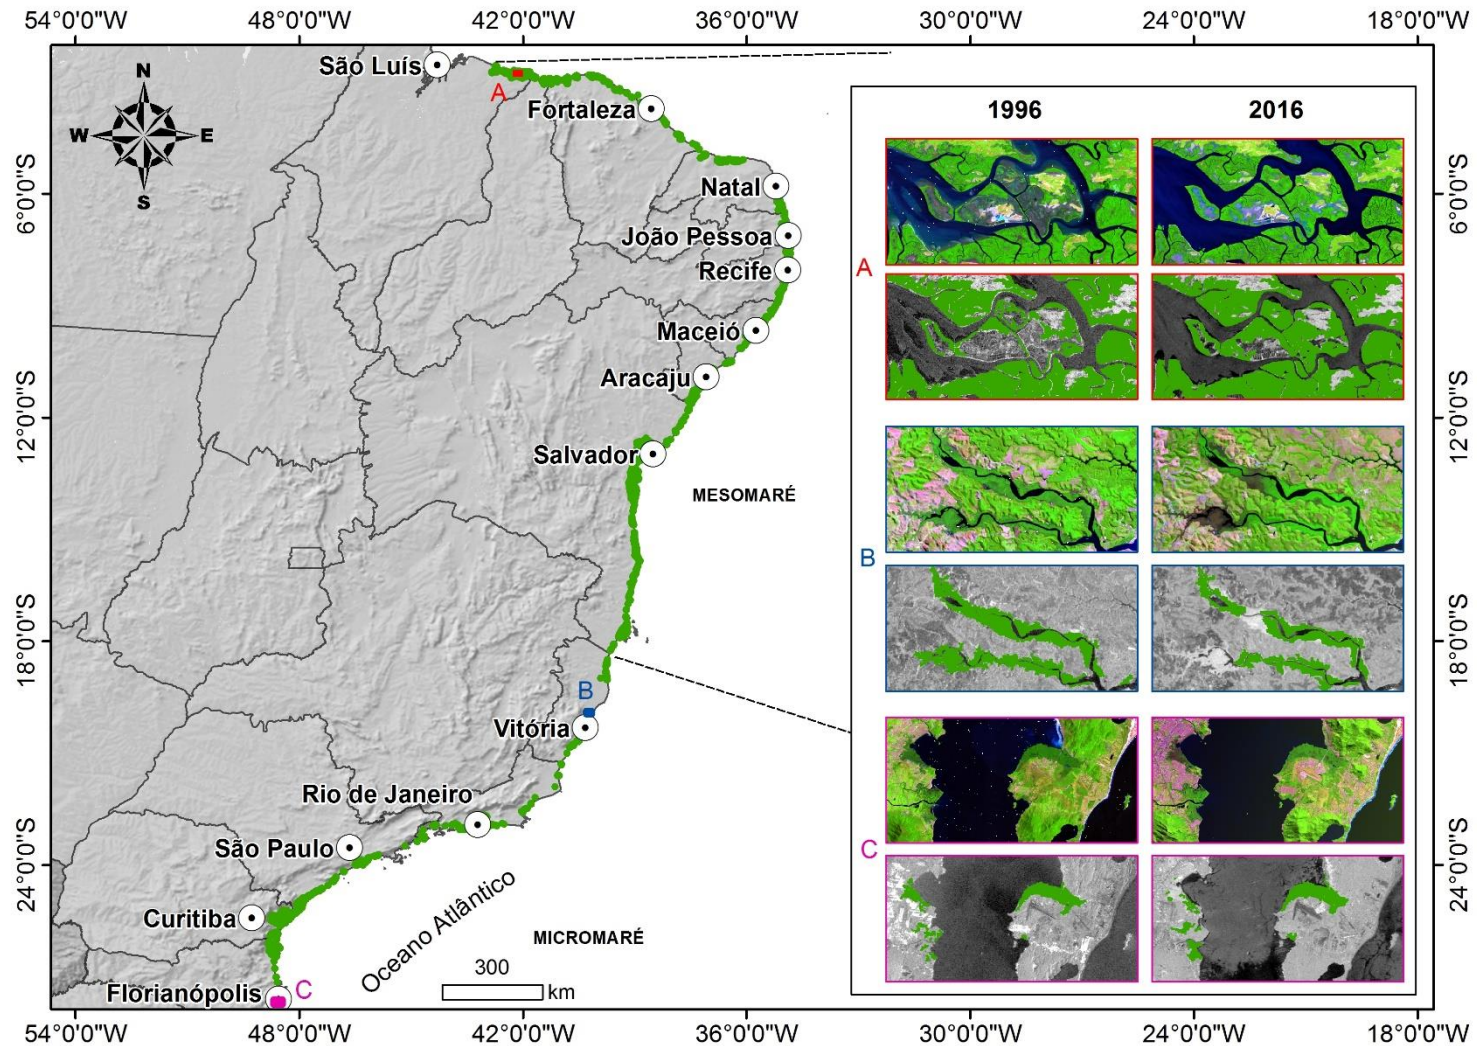


Figura 5- Mapa ilustrativo da região de mesomaré (RME) e micromaré (RMI). A esquerda do mapa foram utilizadas imagens SRTM como fundo delimitando a área do Brasil. A tabela a direita representa as imagens Landsat 5 (1996) e Landsat 8 (2016) e suas respectivas classificações em diferentes setores da costa com imagens SAR ao fundo. Em A - Região da ilha do carrapato (MA); B - Foz do rio Piraquê-açu (ES) e C - Ilha Santa Catarina (SC).

Ao fragmentarmos esses dados para as duas regiões estudadas a RME tinha em 1996 um total de 1983,87 km² passando para 2109,26 km² em 2016. Já a RMI continha em 1996 um total de 641,51 km² e também mostrou crescimento passando para 789,0 km² de áreas de mangue em 2016. Dentre os 14 estados litorâneos estudados o que apresentou maiores concentrações de florestas de mangue foi o estado da Bahia e o menor foi Alagoas (Tabela 5).

Tabela 5- Áreas de manguezais em 1996 e 2016 por estado e suas respectivas porcentagens em relação ao total

Estados	1996		2016	
	Km ²	%	Km ²	%
Maranhão	373,14	14,21	390,21	13,46
Piauí	55,83	2,13	59,15	2,04
Ceará	173,21	6,60	166,43	5,74
Rio Grande do Norte	115,78	4,41	128,56	4,44
Paraíba	112,10	4,27	114,14	3,94
Pernambuco	154,46	5,88	161,58	5,58
Alagoas	51,23	1,95	55,45	1,91
Sergipe	224,25	8,54	241,71	8,34
Bahia	723,87	27,57	792,01	27,33
Espírito Santo	63,01	2,40	61,86	2,13
Rio de Janeiro	98,82	3,76	119,26	4,11
São Paulo	161,42	6,15	208,27	7,19
Paraná	241,50	9,20	308,79	10,65
Santa Catarina	76,76	2,92	90,83	3,13
Total	2625,38	100	2898,26	100

4.3 DETECÇÃO DE MUDANÇAS NAS ÁREAS DE MANGUEZAIS

A análise de detecção de mudanças foi realizada a partir de nova matriz de erros contendo os desacordos de quantidade e alocação. Como já mencionado anteriormente a área de estudo apresentou uma tendência de crescimento de áreas de mangue, com um aumento

geral de aproximadamente 273 km² de mangues, que representam um pouco mais de 10% em relação ao primeiro ano estudado (1996).

Analisando de forma fragmentada os dados de detecção de mudanças orientadas ao objeto é possível separar esses dados em 3 grandes grupos que demonstram crescimento, perda e áreas de mangue que permaneceram inalteradas. Somando toda a área de estudo houve um ganho total de 684,55 km², perda total de 411,68 km², porém a grande maioria dos bosques de mangue permaneceram inalteradas, totalizando 2213,70 km². A tabela 6 separa os ganhos, perdas e estabilidade em áreas de mangue e suas respectivas taxas por estado.

Tabela 6- Estimativa de mudança das áreas de mangue por estado do sudeste e sul brasileiro entre os anos 2008 e 2016

Estados	Área 1996 (km ²)	Área 2016 (km ²)	Área inalterada		Área reduzida		Área expandida	
			(km ²)	(%)	(km ²)	(%)	(km ²)	(%)
Maranhão	373,14	390,21	356,26	95,48	16,88	4,52	33,95	9,10
Piauí	55,83	59,15	53,50	95,83	2,33	4,17	5,66	10,14
Ceará	173,21	166,43	131,44	75,88	41,77	24,11	34,98	20,19
Rio Grande do Norte	115,78	128,56	96,20	83,09	19,58	16,91	32,36	27,95
Paraíba	112,10	114,14	102,73	91,64	9,37	8,36	11,41	10,18
Pernambuco	154,46	161,58	136,44	88,33	18,02	11,67	25,14	16,28
Alagoas	51,23	55,45	36,38	71,01	14,85	28,98	19,07	37,22
Sergipe	224,25	241,71	181,61	80,99	42,64	19,01	60,10	26,80
Bahia	723,87	792,01	597,58	82,55	126,29	17,45	194,43	26,86
Espírito Santo	63,01	61,86	44,74	71,01	18,27	29,00	17,12	27,17
Rio de Janeiro	98,82	119,26	83,37	84,37	15,45	15,63	35,89	36,32
São Paulo	161,42	208,27	132,44	82,05	28,98	17,95	75,83	46,98
Paraná	241,50	308,79	203,52	84,27	37,98	15,73	105,27	43,59
Santa Catarina	76,76	90,83	57,49	74,90	19,27	25,10	33,34	43,43
Total	2625,38	2898,26	2213,70	84,32	411,68	15,68	684,55	26,07

A tabela 6 mostra que as áreas inalteradas apresentaram um percentual médio de aproximadamente 84%, com taxas de inalteração máxima observada no estado do Piauí (95,83%) e mínima no Espírito Santo e Alagoas, ambos com ~71,01%. O percentual de áreas

de expansão de manguezal apresentou valor médio de ~26%, valor máximo de ~47% em São Paulo e mínimo de 9,1% na porção mapeada do estado do Maranhão. Quanto ao percentual de áreas perdidas, o valor médio foi da ordem de 15,6%, com valor máximo de 29% no Espírito Santo e mínimo de 4,17 % no Piauí. A figura 6 ilustra graficamente o balanço entre as perdas e ganhos de áreas de mangue por cada estado.




Figura 6- Balanço em porcentagem de manguezais entre os dois períodos estudados. Somente em dois estados as perdas foram mais significativas que os ganhos de áreas de mangue

A avaliação da acurácia da detecção de mudanças também foi feita nos moldes das classificações mostradas acima. A partir de distribuição aleatória de 1400 pontos foram obtidos uma acurácia global de 78,43%, com 21,57% de desacordo. Os desacordos de quantidade representam 11,86% enquanto que os desacordos alocação representam 9,71%. Os maiores desacordos de quantidade são referentes a classe “Mangue inalterado” e os maiores desacordos de alocação são referentes a classe “Ganho de Mangue” com 11,86 e 9,71% respectivamente.

As mudanças que ocorrem na área de estudos estão representadas na figura 7 através de um mapa de detecção de mudanças com disposição de ganhos, perdas e áreas inalteradas.

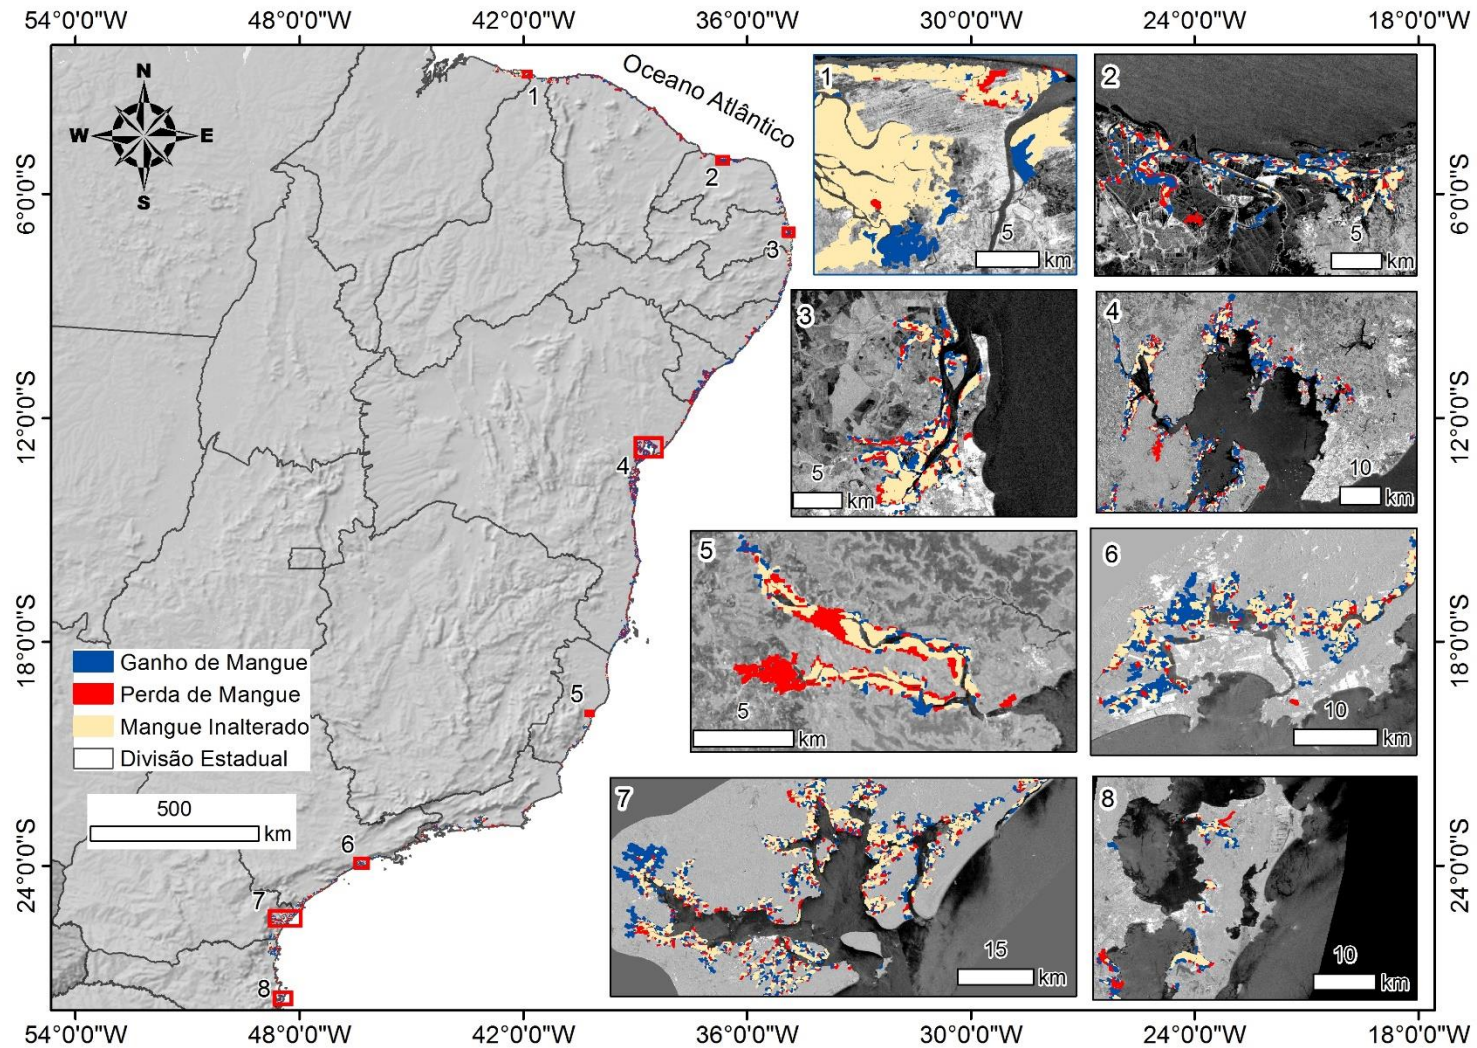


Figura 7- Mapa de detecção de mudanças com destaques para 8 áreas ao longo da RME e RMI. 1- Delta do Parnaíba (MA/PI), 2 – Região de Macau (RN), 3 – João Pessoa (PB); 4 – Baía de Todos os Santos (BA); 5 – Foz do rio Piraquê-açu (ES); 6 - Baía de Santos (SP); 7- Complexo Estuarino de Paranaguá (PR); 8 – Região da Ilha de Santa Catarina (SC).

A matriz de confusão gerada para a detecção de mudanças também seguiu a mesma metodologia das classificações anteriores, com o incremento das estimativas de áreas de (Olofsson *et al.* 2014), os quais propõem o uso de estimadores derivados do mapa de referência para estimar a população (Área total) das classes mapeadas, bem como parâmetros de precisão menos tendenciosos. A tabela 7 resume os principais dados obtidos nessa matriz.

Tabela 7- Tabela resumindo a matriz de confusão gerada para a detecção de mudanças para MRE e MRI. A parte superior da tabela faz um comparativo entre os dados obtidos diretamente neste trabalho e os valores ajustados segundo a metodologia de Olofsson *et al.* (2014). A parte inferior da tabela resume os principais dados provenientes da matriz de confusão utilizada para detecção de mudanças dessa dissertação: Acurácia Global (AG); Desacordo Global (DG); Desacordo em Quantidade (DQ) e Desacordo por Alocação (DA)

CLASSES	Dados Calculados	Dados ajustados segundo Olofsson <i>et al.</i> (2014)	
PERDA	411,7	414 ± 43,3	
GANHO	684,7	590 ± 48	
INALTERAÇÃO	2213	2305 ± 60,3	
AG = 78,43	DG = 21,57	DQ = 11,86	DA = 9,71

As estimativas de áreas de Olofsson *et al.* (2014) fazem ajustes nas quantificações das classes Ganho, Perda e inalteração de manguezais. Após os ajustes feitos seguindo esta metodologia as áreas de perda passaram de 411,7km² para 414 ± 43km², as áreas de ganho de vegetação de mangue passaram 684,7 km² para 590 ± 48 km² e as áreas inalteradas de 2213,7 km² passaram para 2305. No geral esses dados nos mostram que a classe “Ganho de Mangue” foi inicialmente superestimada, após os ajustes as áreas excedidas se dividiram entre as outras duas classes, com aumento em ~3 km² para a classe “Perda de Mangue” e um pouco mais de 90 km² para a áreas inalteradas.

Esses dados, mesmo após os ajustes ainda demonstram que houve sim acréscimo de áreas de mangue entre 1996 e 2016, porém em taxas menores.

5 DISCUSSÕES

O mapeamento e quantificação das áreas de ocorrência de mangue na RME e RMI obtiveram excelentes resultados segundo a acurácia global, índices Kappa (Congalton & Green 2019), e Tau (Ma & Redmond 1995), e a avaliação de mudanças que as mesmas experimentaram durante duas décadas de mapeamento obtiveram bons resultados segundo a metodologia de Pontius Jr & Millones (2014), apesar da quantidade expressiva de desacordos, menos de 10% nos mapeamentos de cada ano (1996 e 2016) e um pouco mais de 20% nas detecções de mudanças entre os períodos analisados, eles foram bem distribuídos entre ganhos e perdas. As maiores taxas de erros de quantidade se justificam pela extensão do mapeamento em regiões com características distintas, que acabam refletindo nas assinaturas espectrais dos manguezais.

Ao compararmos esses dados com o recente levantamento realizado por Diniz *et al.* (2019), que serve de apoio para o projeto Mapbiomas (2019), verificamos certa similaridade nos resultados. Somando todos os estados mapeados, exceto o maranhão (pois a área de trabalho não engloba todo o estado, somente uma parte do mesmo) este estudo quantificou 2252,24 km² e 2508,05 km² respectivamente para 1996 e 2016, já a plataforma Mapbiomas divulga um total de 2047,55 km² e 2349,06 km² de áreas de mangue para os respectivos anos.

Podemos notar que o padrão é similar nos dois trabalhos. Ambos apontam para um crescimento em áreas de mangue entre os períodos estudados. Porém, os valores obtidos neste trabalho, nos dois períodos, foram maiores em relação ao Mapbiomas. Isso pode ser justificado pelo uso associado de dados SAR como apoio na identificação de manguezais encobertos por nuvens, o que conseqüentemente leva a um maior quantitativo em relação ao trabalho de Diniz *et al.* (2019) que utilizaram somente dados ópticos provenientes da série de satélites Landsat. Apesar de metodologias diferentes, podemos comparar os dados, pois os produtos foram gerados a partir de imagens orbitais de sensores com 30m de resolução espacial, porém a complementação do mapeamento utilizando imagens SAR que conseguem adquirir imagens das áreas de mangue sob as nuvens, associado ainda a utilização de GEOBIA, para classificar objetos geográficos, permitem uma maior capacidade de mapeamento das áreas de mangue.

A análise as mudanças das áreas de manguezais na costa nordeste, sudeste e sul do Brasil observa-se um padrão semelhante aquele percebido por Nascimento Jr (2016) ao longo da costa Norte do Brasil entre 1996-2008, onde ~84% dos manguezais permaneceram

inalterados. Quando comparados aos dados de outros países, como a Indonésia e Austrália, percebemos que os manguezais da costa brasileira ainda estão bem preservados, pois a Indonésia teve 41,9% de seus manguezais destruídos (Kusmana 2014) e a China perdeu 48% nos últimos 50 anos (Jia *et al.* 2018).

Todos os estados apresentaram perdas e ganhos de manguezais, porém a maior perda, em km², foi no estado da Bahia com 126,29 km² de áreas de mangue suprimidas, o que representa cerca de 17% da sua área de mangue em 1996 e 30% do total de perdas estimados neste estudo entre todos os estados. As perdas em áreas de mangue poderiam ser explicadas principalmente por dois motivos: i) avanço populacional e pressão antrópica, do ponto de vista ocupacional, sobre os manguezais (Alongi 2002, Trindade 2012) e ii) atividades de aquicultura, principalmente na região Nordeste (Guimarães *et al.* 2012, Queiroz *et al.* 2013).

Embora as ações antrópicas contribuam com a redução de áreas de mangues, as perdas de áreas de floresta de mangue em função da atividade de aquicultura ainda podem ser consideradas diminutas quando leva-se em consideração toda área estudada, pois grande parte tanto da redução como da expansão de áreas de mangues podem também ser associada a dinâmica costeira (Batista *et al.* 2009). As perdas naturais das áreas de mangue ao longo do litoral estão relacionadas a processos de erosão costeira em resposta à ação de onda e marés, ou mesmo ao soterramento da vegetação de mangue por sedimentos arenosos.

Já a expansão de áreas de mangue pode estar ligada a salinização de cursos superiores de estuários (Ellison 1993, Gilman *et al.* 2007), bem como pela progradação de planícies lamosas posteriormente colonizadas por vegetação de mangue em áreas protegidas no interior de baías costeiras (Batista *et al.* 2009, Nascimento Jr *et al.* 2013, Thampanya *et al.* 2006) e elevação relativa do nível do mar (Armitage *et al.* 2015, Cohen *et al.* 2009, Souza-Filho *et al.* 2009).

6 CONCLUSÃO

A utilização combinada de dados de sensores remotos de natureza distinta (reflectância, retroespalhamento, elevação), associados à utilização das técnicas de GEOBIA, a partir de regras de classificação semelhantes, mostraram resultados satisfatórios no mapeamento de manguezais das regiões de micro e mesomaré do litoral brasileiro e representam assim uma alternativa viável para uso em mapeamentos de larga escala na zona costeira. Ao longo das últimas duas décadas, observa-se uma tendência de expansão das áreas dos manguezais ao longo de todos os estados da costa nordeste, sudeste e sul do Brasil, com exceção dos estados do Ceará e Espírito Santo.

Estudos a partir da análise de imagens de sensoriamento remoto para quantificar a área de manguezal na zona costeira do Brasil são cada vez mais crescentes e a maioria converge para o objetivo de acompanhar a dinâmica e auxiliar na conservação deste importante ecossistema costeiro. Esta análise multitemporal foi mais um desses casos e pode ser utilizada no apoio à tomada de decisões para um melhor gerenciamento dos ambientes costeiros brasileiro.

REFERÊNCIAS

- Alongi D.M. 2002. Present state and future of the world's mangrove forests. *Environmental conservation*, **29**: 331-349.
- Alongi D.M. 2008. Mangrove forests: Resilience, protection from tsunamis, and responses to global climate change. *Estuarine, Coastal and Shelf Science*, **76**: 1-13, doi: <https://doi.org/10.1016/j.ecss.2007.08.024>.
- Armitage A.R., Highfield W.E., Brody S.D., Louchouart P. 2015. The contribution of mangrove expansion to salt marsh loss on the Texas Gulf Coast. *PLoS One*, **10**.
- Baatz M. & Schape A. 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strbl J. & Blaschke T. (eds.). *Angewandte geographische informationsverarbeitung*. Wichmann, Heidelberg, Germany. p. 12–23
- Batista E.das.M., Souza Filho P.W.M.e, Silveira O.F.M.da. 2009. Avaliação de áreas deposicionais e erosivas em cabos lamosos da zona costeira Amazônica através da análise multitemporal de imagens de sensores remotos. *Revista Brasileira de Geofísica*, **27**: 83-96.
- Bezerra F.H.R., Rossetti D.F., Oliveira R.G., Medeiros W.E., Brito Neves B.B., Balsamo F., Nogueira F.C.C., Dantas E.L., Andrades Filho C., Góes A.M. 2014. Neotectonic reactivation of shear zones and implications for faulting style and geometry in the continental margin of NE Brazil. *Tectonophysics*, **614**: 78-90.
- Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, **65**: 2-16, doi: <https://doi.org/10.1016/j.isprsjprs.2009.06.004>.
- Blaschke T., Hay G.J., Kelly M., Lang S., Hofmann P., Addink E., Queiroz Feitosa R., van der Meer F., van der Werff H., van Coillie F., Tiede D. 2014. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, **87**: 180-191, doi: <https://doi.org/10.1016/j.isprsjprs.2013.09.014>.
- Blaschke T. & Kux H. 2005. *Sensoriamento remoto e SIG avançados: novos sistemas sensores, métodos inovadores*. São Paulo, Oficina de Textos.
- Cohen M.C.L., Behling H., Lara R.J., Smith C.B., Matos H.R.S., Vedel V. 2009. Impact of sea-level and climatic changes on the Amazon coastal wetlands during the late Holocene. *Vegetation History and Archaeobotany*, **18**: 425.
- Congalton R.G. & Green K. 2019. *Assessing the accuracy of remotely sensed data: principles and practices*. Boca Raton, CRC Press.
- Desclée B., Bogaert P., Defourny P. 2006. Forest change detection by statistical object-based method. *Remote Sensing of Environment*, **102**: 1-11.

- Dillenburg S.R., Barboza E.G., Rosa M.L.C.C., Caron F, Sawakuchi A.O. 2017. The complex prograded Cassino barrier in southern Brazil: Geological and morphological evolution and records of climatic, oceanographic and sea-level changes in the last 7-6 ka. *Marine Geology*, **390**: 106-119.
- Diniz C., Cortinhas L., Nerino G., Rodrigues J., Sadeck L., Adami M., Souza Filho P.W. M. e. 2019. Brazilian mangrove status: three decades of satellite data analysis. *Remote Sensing*, **11**: 808, doi: 10.3390/rs11070808.
- Dominguez J. 2006. The coastal zone of Brazil: an overview. *Journal of Coastal Research*, **39**: 16-20.
- Ellison J.C. 1993. Mangrove retreat with rising sea-level, Bermuda. *Estuarine, Coastal and Shelf Science*, **37**: 75-87.
- Everitt J.H. & Judd F. 1989. Using remote sensing techniques to distinguish and monitor black mangrove (*Avicennia germinans*). *Journal of Coastal Research*, **5**: 737-745.
- Flanders D., Hall-Beyer M., Pereverzoff J. 2003. Preliminary evaluation of eCognition object-based software for cut block delineation and feature extraction. *Canadian Journal of Remote Sensing*, **29**: 441-452, doi: 10.5589/m03-006.
- Gilman E., Ellison J., Coleman R. 2007. Assessment of mangrove response to projected relative sea-level rise and recent historical reconstruction of shoreline position. *Environmental monitoring and assessment*, **124**: 105-130.
- Giri C., Ochieng E., Tieszen L.L., Zhu Z., Singh A., Loveland T., Masek J., Duke N. 2011. Status and distribution of mangrove forests of the world using earth observation satellite data. *Global Ecology and Biogeography*, **20**: 154-159, doi: 10.1111/j.1466-8238.2010.00584.x.
- Glaser M., Krause G., Oliveira R., Fontalvo-Herazo M. 2010. Mangroves and people: a social-ecological system. In: Saint-Paul U. & Schneider H. (eds.). *Mangrove dynamics and management in North Brazil*. Berlin Heidelberg, Springer, 307-351. (Ecological Studies, 211).
- Gonçalves R., Cortes J., Schmidt M., Schimalski M. 2007. Classificação hierárquica e fuzzy de imagens de alta resolução In: 13° Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis, Brasil. *Anais [...]* p. 547-554.
- Grasso M. 2002. *Understanding, modeling and valuing the linkages between local communities and the mangroves of the Caete River Bay (PA-Brazil)*. PhD thesis, Graduate School of the University of Maryland, US, 554 p.
- Green E.P., Clark C.D., Mumby P.J., Edwards A.J., Ellis A.C. 1998. Remote sensing techniques for mangrove mapping. *International Journal of Remote Sensing*, **19**: 935-956, doi: 10.1080/014311698215801.
- Guimarães J.T.F., Cohen M.C.L., Pessenda L.C.R., França M.C., Smith C.B., Nogueira A.C.R. 2012. Mid-and late-Holocene sedimentary process and palaeovegetation changes near the mouth of the Amazon River. *The Holocene*, **22**: 359-370.

Herz R. 1991. *Manguezais do Brasil*. São Paulo, Instituto Oceanográfico, Universidade de São Paulo. 227 p.

ICMBio 2018. *Atlas dos manguezais do Brasil*. Brasília, DF, ICMBio

Jensen J., Lin H., Yang X., Ramsey, Elijah, Ramsey Iii E., Davis B., Thoemke C. 1991. The measurement of mangrove characteristics in southwest Florida using SPOT multispectral data. *Geocarto International*, **6**, doi: 10.1080/10106049109354302.

Jia M., Wang Z., Zhang Y., Mao D., Wang C. 2018. Monitoring loss and recovery of mangrove forests during 42 years: the achievements of mangrove conservation in China. *International Journal of Applied Earth Observation and Geoinformation*, **73**: 535-545, doi: <https://doi.org/10.1016/j.jag.2018.07.025>.

Knoppers B., Ekau W., Figueiredo Jr A. 1999. The coast and shelf of east and northeast Brazil and material transport. *Geo-Marine Letters*, **19**: 171-178, doi: 10.1007/s003670050106.

Kovacs J.M., Wang J., Flores-Verdugo F. 2005. Mapping mangrove leaf area index at the species level using IKONOS and LAI-2000 sensors for the Agua Brava Lagoon, Mexican Pacific. *Estuarine, Coastal and Shelf Science*, **62**: 377-384, doi: <https://doi.org/10.1016/j.ecss.2004.09.027>.

Kusmana C. 2014. Distribution and current status of mangrove forests in Indonesia. In: Faridah-Hanum I., Hakeen A.L.K.R., Ozturk M. (ed.). *Mangrove ecosystems of Asia - status, challenges and management strategies*. New York, Springer, p. 37-60.

Ma Z. & Redmond R.L. 1995. Tau coefficients for accuracy assessment of classification of remote sensing data. *Photogrammetric Engineering and remote sensing*, **61**: 435-439.

Nascimento Jr W.R., Souza-Filho P.W.M.e, Proisy C., Lucas R.M., Rosenqvist A. 2013. Mapping changes in the largest continuous Amazonian mangrove belt using object-based classification of multisensor satellite imagery. *Estuarine, Coastal and Shelf Science*, **117**: 83-93.

Nascimento Júnior W. R. 2016 *Análise da dinâmica das áreas de manguezal no litoral Norte do Brasil a partir de dados multisensores e hidrossedimentológicos*. Phd Thesis, Programa de Pós-Graduação em Geologia e Geoquímica, Universidade Federal do Pará, Belém, Belém, UFPA, 132 p.

Olofsson P., Foody G.M., Herold M., Stehman S.V., Woodcock C.E., Wulder M.A. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, **148**: 42-57.

Pontius Jr R.G. & Millones M. 2011. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, **32**: 4407-4429.

Queiroz L., Rossi S., Meireles J., Coelho C. 2013. Shrimp aquaculture in the federal state of Ceará, 1970–2012: trends after mangrove forest privatization in Brazil. *Ocean & Coastal Management*, **73**: 54-62.

Ramsey Iii E., Nelson G., Sapkota S. 1998. Classifying coastal resources by integrating optical and radar imagery and color infrared photography. *Mangroves and Salt Marshes*, **2**: 109-119, doi: 10.1023/A:1009911224982.

Rodrigues S.W.P. & Souza-Filho P.W.M. e. 2011. Use of multi-sensor data to identify and map tropical coastal Wetlands in the Amazon of Northern Brazil. *Wetlands*, **31**: 11-23, doi: 10.1007/s13157-010-0135-6.

Salum R.B., Souza-Filho P.W.M. e, Simard M., Silva C.A., Fernandes M.E.B., Cougo M.F., do Nascimento W., Rogers K. 2020. Improving mangrove above-ground biomass estimates using LiDAR. *Estuarine, Coastal and Shelf Science*, **236**: 106585, doi: <https://doi.org/10.1016/j.ecss.2020.106585>.

Santos D.C. 2012. *Reconhecimento e mapeamento de gêneros de mangue a partir de dados espectrorradiométricos e imagens ikonos na Ilha de Marajó–Pa*. Dissertation, Programa de Pós-Graduação em Geologia e Geoquímica, Instituto de Geociências, Universidade Federal do Pará, Belém, 61p.

Schaeffer-Novelli Y. 1995. *Manguezal ecossistema entre a terra e o mar*. São Paulo, Caribbean Ecological Research.

Singhroy V. 1996. Interpretation of SAR Images for Coastal Zone Mapping in Guyana. *Canadian Journal of Remote Sensing*, **22**: 317-328, doi: 10.1080/07038992.1996.10855187.

Souza Filho P.W.M.e. & Paradella W.R. 2005. Use of RADARSAT-1 fine mode and Landsat-5 TM selective principal component analysis for geomorphological mapping in a macrotidal mangrove coast in the Amazon Region. *Canadian Journal of Remote Sensing*, **31**: 214-224, doi: 10.5589/m05-009.

Souza-Filho P.W.M.e, Giannini T.C., Jaffé R., Giulietti A.M., Santos D.C., Nascimento W.R., Jr., Guimarães J.T.F., Costa M.F., Imperatriz-Fonseca V.L., Siqueira J.O. 2019. Mapping and quantification of ferruginous outcrop savannas in the Brazilian Amazon: a challenge for biodiversity conservation. *PLoS One*, **14**: e0211095, doi: 10.1371/journal.pone.0211095.

Souza-Filho P.W.M.e, Lessa G.C., Cohen M.C., Costa F.R., Lara R.J. 2009. The subsiding macrotidal barrier estuarine system of the eastern Amazon coast, Northern Brazil. In: Dillenburg S.R. & Hesp P.A. *Geology and geomorphology of Holocene coastal barriers of Brazil*. Hildenberg, Berlin, Springer-Verlag, p. 347-375. (Lecture Notes in Earth Sciences-LNES, 107).

Souza-Filho P.W.M.e, Nascimento W.R., Santos D.C., Weber E.J., Silva R.O., Siqueira J.O. 2018. A GEOBIA approach for multitemporal land-cover and land-use change analysis in a tropical Watershed in the Southeastern Amazon. *Remote Sensing*, **10**: 1683.

Souza-Filho P.W.M.e, Paradella W.R., Rodrigues S.W.P., Costa F.R., Mura J.C., Gonçalves F.D. 2011. Discrimination of coastal wetland environments in the Amazon region based on multi-polarized L-band airborne Synthetic Aperture Radar imagery. *Estuarine, Coastal and Shelf Science*, **95**: 88-98, doi: <https://doi.org/10.1016/j.ecss.2011.08.011>.

- Souza C. & Azevedo T. 2017. *MapBiomass general handbook*; MapBiomass. São Paulo, Brazil, p. 1-23.
- Stehman S.V. & Czaplewski R.L. 1998. Design and Analysis for Thematic Map Accuracy Assessment: Fundamental Principles. *Remote Sensing of Environment*, **64**: 331-344, doi: [https://doi.org/10.1016/S0034-4257\(98\)00010-8](https://doi.org/10.1016/S0034-4257(98)00010-8).
- Story M. & Congalton R.G. 1986. Accuracy assessment: a user's perspective. *Photogrammetric Engineering and remote sensing*, **52**: 397-399.
- Strahler A.N. & Strahler A.H. 1991. Geografía física. *Estudios Geográficos*, **52**: 187.
- Terchunian A., Klemas V., Segovia A., Alvarez A., Vasconez B., Guerrero L. 1986. Mangrove mapping in Ecuador: the impact of shrimp pond construction. *Environmental Management*, **10**: 345-350, doi: [10.1007/BF01867258](https://doi.org/10.1007/BF01867258).
- Thampanya U., Vermaat J., Sinsakul S., Panapitukkul N. 2006. Coastal erosion and mangrove progradation of Southern Thailand. *Estuarine, Coastal and Shelf Science*, **68**: 75-85.
- Trindade L.C. 2012. *Os manguezais da Ilha de Santa Catarina frente à antropização da paisagem*. Dissertation, Centro Tecnológico, Programa de Pós-Graduação em Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis, 220 p.
- Walter V. 2004. Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, **58**: 225-238, doi: <https://doi.org/10.1016/j.isprsjprs.2003.09.007>.
- Yaney-Keller A., Santidrián Tomillo P., Marshall J.M., Paladino F.V. 2019. Using Unmanned Aerial Systems (UAS) to assay mangrove estuaries on the Pacific coast of Costa Rica. *PLoS One*, **14**: e0217310, doi: [10.1371/journal.pone.0217310](https://doi.org/10.1371/journal.pone.0217310).
- Zimudzi E., Sanders I., Rollings N., Omlin C. 2019. Segmenting mangrove ecosystems drone images using SLIC superpixels. *Geocarto International*, **34**: 1648-1662, doi: [10.1080/10106049.2018.1497093](https://doi.org/10.1080/10106049.2018.1497093).